

SISTEMA MONITOREO DE DESGASTE PARA CADENAS DE MOTOCICLETAS

Adrián Sebastián Valencia Sandoval

FUNDACIÓN UNIVERSITARIA LOS LIBERTADORES
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
BOGOTÁ D. C.
2019

SISTEMA MONITOREO DE DESGASTE PARA CADENAS DE MOTOCICLETAS

Adrián Sebastián Valencia Sandoval

TRABAJO DE GRADO PRESENTADO PARA OPTAR EL TÍTULO DE
INGENIERO ELECTRÓNICO

DIRECTOR

Andrés Camilo Jiménez Álvarez
MsC. INGENIERÍA ELECTRÓNICA

FUNDACIÓN UNIVERSITARIA LOS LIBERTADORES
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA DE ELECTRÓNICA
BOGOTÁ D. C.
2019

Nota de Aceptación

Firma del presidente del Jurado

Firma del Jurado

Firma del Jurado

BOGOTA D.C. MARZO 2019

Las directivas de la Fundación los libertadores, los jurados calificadores y el cuerpo docente no son responsables por los criterios e ideas expuestas en el presente documento. Estos corresponden únicamente al autor.

DEDICATORIA

A mi madre, que, sin lugar a dudas, sin su apoyo incondicional,
nada de esto habría sido posible, Gracias madre.

AGRADECIMIENTOS

Deseo expresar mi agradecimiento a todos y cada uno de aquellos en los que compartieron un momento para brindarme apoyo o conocimiento, en especial, al Ingeniero Andrés Camilo Jiménez Álvarez, por el acompañamiento, apoyo e interés, pero sobre todo del conocimiento del cual me es muy gratificante ya que permitió llegar a la culminación de esta investigación.

Tabla de contenido

	Pág.
LISTA DE FIGURAS.....	9
LISTA DE TABLAS	11
INTRODUCCIÓN.....	12
OBJETIVOS	13
OBJETIVO GENERAL	13
OBJETIVOS ESPECÍFICOS	13
PLANTEAMIENTO DEL PROBLEMA.....	14
JUSTIFICACIÓN.....	15
ESTADO DEL ARTE	16
1. MARCO TEÓRICO	17
1.1. Sistemas mecánicos	17
1.2. Sistemas mecánicos para transmisión de energía	17
1.3. Mantenimiento Predictivo	19
1.4. Detección De Ultrasonido	20
2. Estimación de características dinámicas a partir de representaciones tiempo-frecuencia.	21
2.1. Análisis de Fourier	21
2.2. Espectrograma-STFT	21
2.3. Transformada de Wavelet	23
2.4. Transformada wavelet continua	24
2.5. Escalograma-CWT	24
2.6. Transformada por paquetes wavelet (WPT)	26
2.7. MFCC (Mel-Frequency Cepstral Coefficients).....	28
2.8. Filterbank	29
3. Algoritmos De Clasificación	30
4. Marco experimental	35
4.1. Cálculo de representaciones tiempo-frecuencia	38
4.2. Extracción de características dinámicas	38
4.3. Preprocesamiento de la señal	39
4.4. Wavelet, Filtrado, Escala o Resolución	41

4.5.	Extracción Coeficientes en la escala de Mel.....	42
4.6.	Clasificación	42
4.7.	Matriz de Confusión.....	44
4.8.	Curva Roe	45
5.	Validación	46
6.	Discusión Y Conclusiones	48
6.1.	Trabajo a futuro	50
Apéndice A	51
Apéndice B.....		56
Apéndice C		61
Apéndice D		64
Apéndice E.....		67
7.	Bibliografía	71

LISTA DE FIGURAS

pág.

1. Figura. Sistema mecánico de transmisión por cadena	18
2. Figura. Mecanismos	19
3. Figura. Representación gráfica de un espectrograma con sus componentes Tiempo, Frecuencia, Amplitud	22
4. Figura. Ventaneo y resolución en la STFT	23
5. Figura. Representación gráfica de un escalograma con sus componentes Tiempo, Frecuencia, Amplitud	25
6. Figura. Resolución de la Transformada Wavelet Discreta	25
7. Figura. Algoritmo piramidal con DWT	27
8. Figura. Algoritmo piramidal de 3 niveles con WPT -A Coeficientes de aproximación - Coeficientes de detalle	27
9. Figura. Descomposición de la información	27
10. Figura. Filterbank	28
11. Figura. Escala de frecuencias de MEL	30
12. Figura. Transformación no lineal a priori del espacio de entrada al espacio de características	34
13. Figura. Promedio de 100 suavizantes, cada uno ajustado a un subconjunto del conjunto de datos original, llegamos a un predictor embolsado	35
14. Figura. Metodología Organigrama	36
15. Figura. Ajuste de las muestras y extracción de características	37
16. Figura. Espectrograma del comportamiento de una muestra sin lubricar (Izquierda) y lubricada (Derecha)	40
17. Figura. Escalograma del comportamiento de una muestra sin lubricar (Izquierda) y lubricada (Derecha)	40
18. Figura. Filtrado de la señal completa.....	41
19. Figura. Filtrado de la señal a detalle primeros Mil datos	42
20. Figura. Superior Izq. muestra de cadena sin lubricar, Superior Der. lubricada y sus correspondientes filtradas en la parte inferior	42
21. Figura. Correspondientes filtradas	42
22. Figura. Fase de clasificación	43
23. Figura. Matriz de confusión de modelo Ensamble Subespacios KNN	45
24. Figura. Gráfica en porcentajes equivalentes a los datos	45
25. Figura. Curva ROC del modelo Ensamble Subespacios KNN Predicción Lubricada.....	46

26. Figura. Curva ROC del modelo Ensamble Subespacios KNN Predicción	
No Lubricada	46

LISTA DE TABLAS

	Pág.
1. Tabla. Características de Clasificación	42
2. Tabla 2a. Validación de los algoritmos de Clasificación	45
3. Tabla 2b. Validación de los algoritmos de Clasificación	46

INTRODUCCIÓN

Los sistemas mecánicos que están sometidos a rozamiento necesitan una película de lubricante para un correcto funcionamiento y una vida prolongada reduciendo el desgaste. Estos sistemas después de un tiempo de trabajo pierden lubricante, lo cual ocasiona un desgaste proporcional al trabajo ejercido en esta condición, ya que al ser dos o más piezas sólidas (sea metal y/o derivados) que están sometidas a una fricción constante, tienden a generar desgastes si este no presenta la lubricación adecuada. Para una óptima lubricación se debe tener establecidos los periodos de mantenimiento, este factor está determinado de acuerdo con el trabajo y condiciones ambientales a las que sea sometido.

Existen métodos para llevar a cabo una detección de falta de lubricante, Manuales y Centralizados o Automatizados, el manual como tiene la particularidad de ser un método variable ya que este depende únicamente de la observación y ejecución siendo este un método subjetivo ya que depende del observador, y está el método automático de lazo abierto, este también presenta inconvenientes ya que comúnmente se utiliza bajo parámetros de tiempo [1],

El sistema más utilizado y que menor costo presenta en la industria está basado en periodos de tiempo, también existe el de señal retroalimentada, este sistema generalmente utiliza un sensor de tipo inductivo o capacitivo el cual dependiendo de sus parámetros ajusta la respuesta de salida, el problema con este, es la limitación que presenta en algunas aplicaciones, y por último se encuentran los equipos especializados para la detección de fallas mecánicas basadas en audio en la banda de ultrasonido.

Este es un equipo de alta precisión [2] ya que caracteriza el sistema mecánico, definiendo su comportamiento relación tiempo-frecuencia [3] y el estado en que se encuentra, dando una respuesta de posibles fallas del sistema. Este, al igual que los anteriores métodos, presenta problemas, ya que es una combinación entre operador-equipo, y su elevado costo hace que sea un método casi que limitado.

Para fines de esta investigación se plantea una metodología que realice el procesamiento, extracción de características principales bajo análisis tiempo-frecuencia por métodos no paramétricos para su posterior clasificación. Se realizó la toma de 40 muestras de audio que se extrajeron de 20 motocicletas antes y después de lubricar la cadena de tracción, las muestras son transformadas al dominio de la frecuencia inicialmente, para poder ver su comportamiento y poder hacer una identificación de sus características gráficamente con el espectrograma, siendo este el punto de partida para realizar un análisis del comportamiento.

OBJETIVOS

OBJETIVO GENERAL:

Diseñar un sistema para la detección de patrones donde se identifique la diferencia entre una cadena de motocicleta esté lubricada, o carezca de esta propiedad.

OBJETIVOS ESPECÍFICOS:

1. Analizar la señal (muestras de audio) aplicando técnicas en Tiempo-Frecuencia basado en el espectrograma STFT (Transformada de Fourier de Tiempo Reducido) Y escalograma de la CWT (Transformada continua de Wavelet).
2. Extraer información relevante aplicando diferentes filtros en frecuencia y en la densidad espectral de potencia.
3. Implementar algoritmos de clasificación, sobre los datos arrojados de los filtros basados en frecuencia y en la densidad espectral de potencia.
4. Validar el sistema al aplicar los algoritmos de clasificación.

PLANTEAMIENTO DEL PROBLEMA

La lubricación en el tren trasero de tracción de la motocicleta, debe estar en óptimas condiciones de operación, para evitar una posible falla mecánica, la cual puede desencadenar en un accidente. El único dispositivo que actualmente se encuentran en el mercado, se basan en un sistema de control de lazo abierto, este, realiza la lubricación cada determinado periodo de tiempo, el cual no varía, siendo una constante fija. Partiendo de aquí se encuentra, que las condiciones ambientales, de trabajo y los componentes físicos del sistema hacen que el periodo de lubricación varíe, y por ende en ciertas condiciones puede presentarse una falta de lubricante o lo contrario, un exceso del mismo, en ambos casos, presentando problemas.

En el primero generando desgaste, y en el segundo, aunque no tan grave como este, si genera un impacto ambiental, ya que un exceso de lubricante terminará siendo arrojado al medio ambiente. Aunque el sistema brinda una solución con sus respectivas falencias, es ineficiente al no se adaptarse a las condiciones de trabajo, por ende, se plantea un sistema que monitoree las condiciones operativas del sistema y de acuerdo a estas se determine el momento adecuado para realizar una correcta lubricación del sistema, así se tendría el control completo, de en qué momento lubricar y que cantidad de lubricante aplicar.

JUSTIFICACIÓN

Una mala lubricación en un sistema mecánico puede conllevar a varios problemas, el principal y el más importante es una posible falla mecánica que pueda terminar en un accidente. El parque automotor en Colombia según la base de datos del último reporte del RUNT (Registro único nacional de tránsito) está en la cifra de 12'623.300, de esta cifra 7'064.316 son motocicletas, la cual, lidera la cifra en preferencia como medio de transporte a nivel nacional, pero, también lidera la lista de accidentalidad a nivel nacional, al 2016 este presentaba el 48% de accidentes, estos se divide en tres causas fundamentales, la primera y encabeza la lista es, el exceso de velocidad, el no acatamiento de las normas de tránsito, la conducción en estado de embriaguez y la última, fallas mecánicas, todas estas se pueden evitar.

Para efecto de este proyecto nuestro interés está basado en las fallas de carácter mecánico, específicamente, fallas en el sistema de tracción de las motocicletas (piñón principal, cadena y piñón trasero) los cuales, al no presentar un mantenimiento constante, genera desgaste en estas piezas conllevando a una rotura de alguno de estos componentes.

Este proyecto busca mitigar esta falla con la implementación de un sistema que monitoree las condiciones del sistema mecánico en mención y nos genere una óptima lubricación, manteniendo operativo el sistema, evitando fallas mecánicas o problemas en el cese de una actividad dependiente del sistema, hasta su arreglo, en el caso de las motocicletas, un problema grave sería provocar un accidente vehicular, generando consecuencias físicas y monetarias, ambas tienen una índole consecuente grave y la idea de este proyecto es mitigar ambas posibilidades que se pueden generar por una falta de lubricación en el tren trasero de las motocicletas, alargando además la vida útil del sistema y por ende ahorros significativos de operación.

Por lo anterior, resolver este problema, se centra en la necesidad de proponer una metodología que genere una correcta detección de falta de lubricante en la cadena, este método nos daría la certeza de cuando es necesario realizar la correcta lubricación.

MARCO REFERENCIAL

A mediados de los años 70 el señor Robert Randall trabajador de BRÜEL & KJÆR, empresa especializada en el diseño de equipos para medir y caracterizar la calidad del sonido y la vibración, escribe uno de los primeros artículos, siendo este, una nota de aplicación para los equipos que en ese momento estaban en producción para la detección de fallas, “Análisis de Cepstrum y Diagnóstico de Fallas en la Caja de Engranajes” utilizando como base principal, la detección de la periodicidad en un espectro de frecuencias, detectando la presencia de bandas laterales espaciadas a intervalos iguales alrededor de una o varias frecuencias.

La presencia de tales bandas laterales es interesante en el análisis de las señales de vibración de la caja de engranajes, ya que varias fallas tienden a causar la modulación del patrón de vibración resultante de la malla dentada, y esta modulación (modulación de amplitud o frecuencia) da lugar a bandas laterales en el espectro de frecuencia. Las bandas laterales se agrupan en torno a la frecuencia de malla dentada y sus armónicos, espaciadas en múltiplos de las frecuencias moduladoras [4] y la determinación de estas frecuencias de modulación puede ser muy útil en el diagnóstico de fallas.

Siendo este la antesala de un sin número de artículos de este autor, donde abrió la puerta al análisis y detección de patrones a partir de muestras de audio. Pero, aunque este es uno de los primeros casos de aplicación, de este tipo, nos debemos remontar unas décadas atrás ya que el Cepstrum fue definido en un artículo de 1963 por Bogert, Healy y Tukey [5].

❖ Algoritmos

El diseño y desarrollo de algoritmos tiene un origen asociado a numerosas disciplinas (la Matemática, la Física...) debido a la búsqueda constante para resolver algún problema ligado a la naturaleza de muchas ciencias. La aplicación de las facilidades de las máquinas automáticas a los algoritmos coincide con la aparición de las primeras máquinas para ordenar o clasificar.

Las dificultades en la elaboración del censo de los Estados Unidos, motivó que un empleado de la oficina del censo, Hollerith, inventara una máquina electromecánica tabuladora para satisfacer las necesidades existentes de reunir datos estadísticos. Desde los procedimientos de solución a un sistema de ecuaciones hasta la toma de decisiones combinatorias en los algoritmos (de grafos, geométricos...) se optimizan notablemente cuando se dispone de una buena rutina de clasificación. Como consecuencia, uno de los estándares que determinan la eficiencia de un procesador utiliza algoritmos de clasificación [6].

1. MARCO TEÓRICO

Se presentan algunos conceptos generales de sistemas mecánicos, extracción de características dinámicas, bajo la relación tiempo-frecuencia, dando enfoque hacia la propuesta que se describe para la detección de fallas mecánicas en la banda del espectro auditivo en la escala de MEL, con el objetivo de aclarar estos conceptos manejados más adelante y que serán de gran apoyo a lo largo del documento.

1.1 Sistemas mecánicos

Los sistemas mecánicos son aquellos sistemas constituidos fundamentalmente por componentes, dispositivos o elementos que tienen como función específica transformar o transmitir el movimiento desde las fuentes que lo generan, al transformar distintos tipos de energía.

Se caracterizan por presentar elementos o piezas sólidos, con el objeto de realizar movimientos por acción o efecto de una fuerza. En ocasiones, pueden asociarse con sistemas eléctricos y producir movimiento a partir de un motor accionado por la energía eléctrica. En general la mayor cantidad de sistemas mecánicos usados actualmente son propulsados por motores de combustión interna.

En los sistemas mecánicos. se utilizan distintos elementos relacionados para transmitir un movimiento. Como el movimiento tiene una intensidad y una dirección, en ocasiones es necesario cambiar esa dirección y/o aumentar la intensidad, y para ello se utilizan mecanismos. En general el sentido de movimiento puede ser circular (movimiento de rotación) o lineal (movimiento de translación) los motores tienen un eje que genera un movimiento circular

1.2 Sistemas mecánicos para transmisión de energía

❖ Sistema de transmisión por cadena

Los sistemas de transmisión por cadena, se emplean, para transmitir movimiento entre dos ejes paralelos, que se encuentran alejados entre sí, aunque las diferentes configuraciones de los elementos que la componen, pueden hacer variar la función final del sistema, es decir, el sistema puede tener la finalidad de transmitir movimiento entre los ejes, servir como sistemas de elevación o como sistema transportador.

Estos sistemas constituyen uno de los métodos más eficientes utilizados para transmitir potencia mecánica

Fig.1 Sistema mecánico de transmisión por cadena



Fuente: OLARTE C., LA DETECCIÓN DE ULTRASONIDO: UNA TÉCNICA EMPLEADA EN EL MANTENIMIENTO PREDICTIVO, 2011, pp. 230-233

Este sistema de transmisión tiene muchas ventajas entre las más importantes están:

- ❖ El sistema de transmisión por cadena, tiene la capacidad de transmitir potencia a una considerable distancia entre ejes, esta condición se logra dado que las cadenas pueden tener longitudes variables, es decir su longitud puede variar mediante la adición o eliminación de eslabones.
- ❖ Con los sistemas de transmisión por cadenas se pueden obtener rendimientos elevados del orden del 98%, dado que se excluyen problemas de deslizamiento entre los componentes del sistema.
- ❖ En este tipo de sistemas no existe tensión previa, por lo que la carga en los árboles es menor que en el caso de sistemas de transmisión por correas.
- ❖ Con el sistema de transmisión por cadenas se puede transmitir rotación a varios árboles o ejes con una misma cadena.
- ❖ Cuando se requieren transmitir potencia elevadas simplemente bastará con emplear múltiples hileras. Algunas de las desventajas que incluye el sistema de transmisión por cadena son:
- ❖ Se requieren montajes precisos con el objetivo de evitar que alguna de las caras de la cadena se someta a cargas superiores y falle por fatiga anticipadamente, es decir se afecte la vida útil de los componentes.
- ❖ Se requieren prácticas de mantenimiento minuciosos y procesos de lubricación. Se pueden presentar manchas irregulares, oscilaciones o choques en trabajos con máquinas alternativas o durante el accionamiento.

El sistema de transmisión por cadena se compone de diversos elementos, dependiendo de su configuración. La configuración más común se compone de dos sprockets (ruedas dentadas) y una cadena de eslabones, aunque en la práctica con el objetivo de evitar que la cadena se salga de las ruedas dentadas que arrastra, se emplean mecanismos de tensión para mantener la tensión de la cadena.


- ❖ **Eslabones:** De forma individual las cadenas se componen de eslabones que a su vez incluyen una serie de elementos que pueden variar en forma y cantidad en función del tipo de cadena. Para el caso de las cadenas de rodillos, se incluyen placas o bridas interiores y exteriores, bujes, rodillos y en algunos casos pines para garantizar la unión de los elementos.

La transmisión por cadena tiene ventajas considerables frente, a la transmisión por correa o con ruedas de fricción, dado que tiene la capacidad de transmitir, potencias mayores empleando cadenas de múltiples hileras y no existen problemas de deslizamiento entre las ruedas y la cadena, porque los eslabones de la cadena quedan enganchados con los dientes de la rueda.

- ❖ **Sprockets:** De forma técnica los sprockets o ruedas dentadas para transmisiones por cadenas se pueden clasificar en dos tipos, las sprockets comerciales y sprockets de precisión. Cuando las velocidades son moderadas se pueden usar sprockets comerciales, pero cuando la velocidad es alta combinada, con altas cargas se recomienda usar sprockets de precisión.

- ❖ **Mecanismos de tensión:** En los sistemas, de transmisión por cadenas no se suelen emplear mecanismos de tensión, dado que las cadenas no son elementos flexibles, pero en algunas ocasiones especiales, se suelen emplear algunos mecanismos para brindar una adecuada tensión y evitar que la cadena se descarrile, en casos donde se presente alguna vibración u oscilación de la cadena.

Fig.2 Mecanismos



Fuente: El Hombre y la Máquina, Luis Enrique Arteaga, núm. 45, 2014, pp. 88-97

1.3. MANTENIMIENTO PREDICTIVO

El mantenimiento predictivo son una serie de acciones que se toman junto a técnicas que se aplican con el objetivo de detectar posibles fallas y defectos de maquinaria en las etapas incipientes para evitar que estos fallos se manifiesten en uno más grande durante su funcionamiento, evitando que ocasionen paros de emergencia y tiempos muertos, causando impacto económico. Su misión es conservar un nivel de servicio determinado en los equipos programando las revisiones en el momento más oportuno. Suele

tener un carácter sistemático, es decir, se interviene, aunque el equipo no haya dado ningún síntoma de tener problemas.

Las ventajas más importantes son:

- ❖ Las fallas se detectan en sus etapas iniciales por lo que se cuenta con suficiente tiempo para hacer la planificación y la programación de las acciones correctivas (mantenimiento correctivo) en paros programados y bajo condiciones controladas que minimizan los tiempos muertos y el efecto negativo sobre la producción.
- ❖ Las técnicas de detección del mantenimiento predictivo son en su mayor parte técnicas "on-condition", que significa que las inspecciones se pueden realizar con la maquinaria en caliente o funcionamiento.

1.4. Detección De Ultrasonido

Uno de los métodos que utiliza el mantenimiento predictivo para detectar fallas en la industria, ejemplo en las plantas industriales y sus cadenas de producción, es el ultrasonido, el cual es un método fácil, rápido y eficaz en ambientes de mucho ruido de baja frecuencia. El ultrasonido sirve para localizar con exactitud, aquellos puntos en donde existen problemas incipientes, permitiendo la programación adecuada del mantenimiento de los equipos, sin entorpecer el desarrollo normal de la empresa. Todos los problemas mecánicos, eléctricos, así como las fugas de presión o vacío generan ondas ultrasónicas, las cuales se detectan mediante medidores de ultrasonido con el fin de ubicar el problema.

Aplicaciones de la Detección de Ultrasonido

- ❖ Entre las aplicaciones más importantes que tiene la detección de ultrasonido se tienen: Monitoreo de Rodamientos, Cualquier tipo de rodamiento, emite ondas de ultrasonido producidas por la fricción entre sus partes.
- ❖ Detección de Fugas de Presión o Vacío: Los medidores de ultrasonido detectan fácilmente el sonido proveniente de la turbulencia ocasionada por un escape de presión o vacío en los sistemas.
- ❖ Inspección de Instalaciones Eléctricas: Las descargas eléctricas y el efecto corona producen ondas ultrasónicas que pueden descubrirse a través del análisis por ultrasonido [8].

2. Estimación de características dinámicas a partir de representaciones tiempo-frecuencia.

La toma de señales a partir de diversidad de sensores, que existen actualmente, nos proporcionan información para representar el comportamiento de sistemas, o de todo aquello de lo que deseemos dar una interpretación en el mundo real, por ejemplo, parámetros atmosféricos, vibración en equipos descompensados, la polución en una ciudad, el comportamiento de un motor, o en general cualquier sistema y su comportamiento, adquiriendo así información que podemos recopilar para su posterior procesamiento, dando origen a muchas aplicaciones incluyendo: análisis, síntesis, filtrado, caracterización-modelado, modulación, detección, estimación, clasificación, supresión, ecualización, codificación y sincronización.

Cuando se busca una representación de señales no estacionarias usando transformadas tiempo-frecuencia, el primer problema a resolver es el de encontrar una función conjunta de tiempo y frecuencia, una distribución, que describa la densidad de energía o intensidad de una señal en tiempo y frecuencia simultáneamente. Existen varios métodos para la descomposición o representación en tiempo frecuencia partiendo como paso inicial en el análisis de Fourier el cual nos da la entrada a la caracterización de los componentes de la señal en el dominio de la frecuencia.

Existe una gran cantidad de técnicas para hallar representaciones espectrales y distribuciones tiempo-frecuencia; sin embargo, es posible clasificarlas en dos categorías mayores: estimación paramétrica y no paramétrica. Los métodos paramétricos requieren un modelo previo de la señal, el cual muchas veces no se tiene a disposición, y en general, es difícil de obtener en los bioseñales debido a su naturaleza. Por este motivo, se elige realizar un análisis no paramétrico, que se puede aplicar puesto que no es necesario asumir un modelo de la señal

2.1. Análisis de Fourier


El análisis de Fourier permite la descomposición de una señal en componentes individuales de frecuencia, sin embargo, no dice cuándo ocurren tales frecuencias. Por tanto, es útil realizar un análisis usando ventanas cortas en el tiempo, con el fin de estudiar el contenido de frecuencia en cada una de estas ventanas, y así obtener una representación de la variación espectral a través del tiempo, este también es quizás su talón de Aquiles, ya que la ventana que se define es fija y puede que en algunos casos donde el cambio del contenido espectral de la señal es tan imperceptible, afecte a la transformación y por ende, a su interpretación, siendo así difícil definir la ventana apropiada para cierto tipos de señales, puesto que puede no haber un intervalo para el cual la señal sea estacionaria. Además, al reducir la ventana en el tiempo para localizar eventos, se reduce la resolución en frecuencia. Así, hay una directa relación entre la resolución en tiempo y en frecuencia [9].

2.2. Espectrograma-STFT (Transformada de Fourier de Tiempo Reducido).

❖ Análisis Gráfico

El espectrograma es el resultado de calcular el espectro de tramas definidas por una ventana temporal de la señal entregando información gráfica tridimensional que representa el contenido frecuencial de la señal según va variando bajo una relación tiempo-frecuencia. Y de aquí surge ¿qué es un espectro? Pues de forma sencilla la transformada de Fourier nos dice que cualquier señal (función en el dominio del tiempo) puede descomponerse en una serie de funciones periódicas (oscilaciones de frecuencia constante) cada una con una frecuencia y amplitud distintas. Si representamos la frecuencia y amplitud obtenemos el espectro (función en el dominio de la frecuencia) que nos dice cuáles son las frecuencias dominantes de esa señal. Con lo cual, el espectrograma nos permite conocer cómo evolucionan las frecuencias que dominan una señal [10]. siendo esta una forma de dar una interpretación al comportamiento frecuencial de una señal dando así la entrada a una interpretación analítica de modo grafico de su comportamiento.

Fig. 3. Representación gráfica de un espectrograma con sus componentes Tiempo, Frecuencia, Amplitud



Fuente: Autor

La STFT es el método clásico de análisis tiempo-frecuencia. El concepto principal de esta transformada es multiplicar la señal $s(t)$, a ser analizada, por una ventana de análisis $g(\tau - t)$, y luego se calcula la transformada de Fourier de la señal ventaneada de acuerdo con

$$T_{STFT}(t, f) = \int_{-\infty}^{\infty} x(\tau) g(\tau - t) e^{-j2\pi f\tau} d\tau \quad (2.1.)$$

La ventana de análisis $g(\tau - t)$ suprime a $x(\tau)$ fuera de determinada región, y la transformada de Fourier produce un espectro local. Típicamente se elige una ventana real con respuesta al impulso de un filtro pasa bajas; sin embargo, es posible aplicar ventanas complejas. Si se elige una función gaussiana como ventana, la

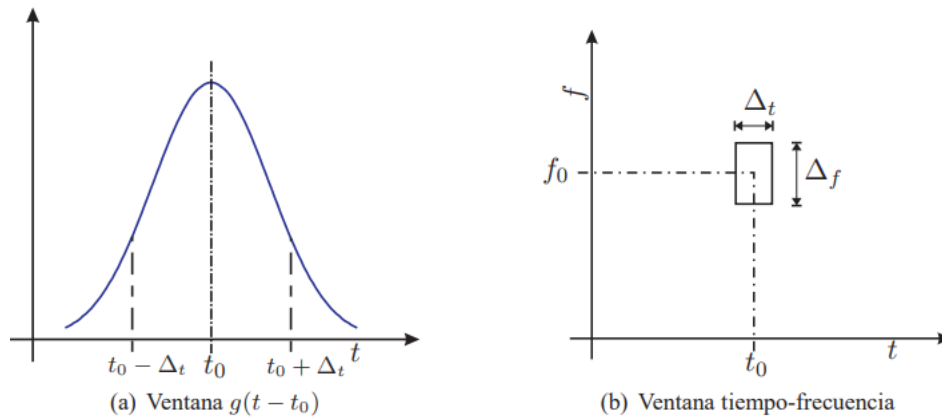
STFT se convierte en la transformada de Gabor, puesto que Gabor introdujo la STFT con este tipo particular de ventana.

La STFT también se puede definir en el dominio de la frecuencia [11]:

$$T_{STFT}(t, f) = e^{-j2\pi\theta t} \int_{-\infty}^{\infty} X(\theta)G(\theta - f)e^{j2\pi\theta t} d\theta \quad (2.2.)$$

La posición de la ventana tiempo-frecuencia es determinada por los parámetros t y f . La forma de la ventana es independiente de t y f , así se obtiene una resolución uniforme en el plano tiempo frecuencia, tal como se puede observar en la Figura 7.

Fig.4. Ventaneo y resolución en la STFT



Fuente: A. Mertins, Signal analysis : Wavelets, filter banks, time-frequency transforms, and applications, 1999, p11

Puesto que la STFT en general no es real, usualmente se usa el espectrograma para visualización o para etapas posteriores de procesamiento. El espectrograma es el cuadrado de la magnitud de la STFT:

$$T_{SPEC}(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) x(\tau - t) e^{-j2\pi f \tau} d\tau \right|^2 \quad (2.3.)$$

2.3. Transformada de Wavelet

La transformada de wavelet al igual que la transformada de Fourier, se usa para extraer información relevante de diferentes tipos de datos. Generalmente se necesitan conjuntos de wavelets para analizar los datos completamente. Un conjunto de wavelets "complementarias" descompondrá los datos sin vacíos evitando ser sobre escritos, de modo que el proceso de descomposición sea matemáticamente reversible. Por lo tanto, los conjuntos de wavelets complementarios son útiles en los algoritmos de compresión/descompresión basados en wavelets en los que es deseable recuperar la información original con una pérdida mínima, comúnmente utilizada en la comprensión de información para que esta ocupe menor espacio un ejemplo claro está en los codes de audios.

2.4. Transformada wavelet continua (CWT – Continuous Wavelet Transform)

La transformada wavelet continua $T_{CWT}(b, a)$ de una señal continua en el tiempo $x(t)$ se define como [13, 14, 15],

$$T_{CWT}(b, a) = |a|^{-\frac{1}{2}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.2.1)$$

Así, la transformada wavelet se calcula como el producto interno entre $x(t)$ y versiones trasladadas y escaladas de la función $\psi(t)$, llamada wavelet.

Si $\varphi(t)$ tiene una respuesta al impulso pasa-banda, entonces el análisis wavelet se puede entender como análisis pasa-banda. Al variar el parámetro de escala a , la frecuencia central y el ancho de banda se modifican. La variación de b se relaciona con una traslación en el tiempo, así que, para un a fijo, la transformada (2.62) se puede interpretar como una convolución de $x(t)$ con la wavelet escalada e invertida en el tiempo,

$$T_{CWT}(t, a) = |a|^{-\frac{1}{2}} x(t) * \varphi \left(\frac{t-b}{a} \right) dt \quad (2.2.2)$$

El factor $|a|^{\frac{1}{2}}$ se introduce con el fin de asegurar que todas las funciones escaladas $|a|^{-\frac{1}{2}} \varphi^* \left(\frac{t}{a} \right)$, con $a \in \mathbb{R}$, tengan la misma energía.


Puesto que la función de análisis $\psi(t)$ se escala y no se modula como la función ventana $g(t)$ de la STFT, el análisis wavelet se llama tiempo-escala y no tiempo-frecuencia.

2.5. Escalograma-CWT (Transformada de wavelet continua)

Así como la STFT (Espectrograma), la transformada wavelet permite medir las variaciones tiempo-frecuencia de componentes espectrales, pero tiene una resolución diferente. La localización en frecuencia es logarítmica, siendo proporcional al nivel de frecuencia. Como consecuencia, la localización en el tiempo es más detallada para las frecuencias más altas tal como se puede observar en las Figuras 2(a) y 2(b). De acuerdo a lo que se observa en la Figura 2(a) la resolución de la CWT en el tiempo es buena para frecuencias altas, pero como el ancho de banda de la wavelet madre se hace grande para estas frecuencias, la resolución en frecuencia no es buena. Y en las frecuencias bajas, la wavelet madre es mucho más ancha en el tiempo y tiene una concentración en frecuencia alta, lo cual permite identificar correctamente componentes de baja frecuencia con el costo de una resolución menor en el tiempo.

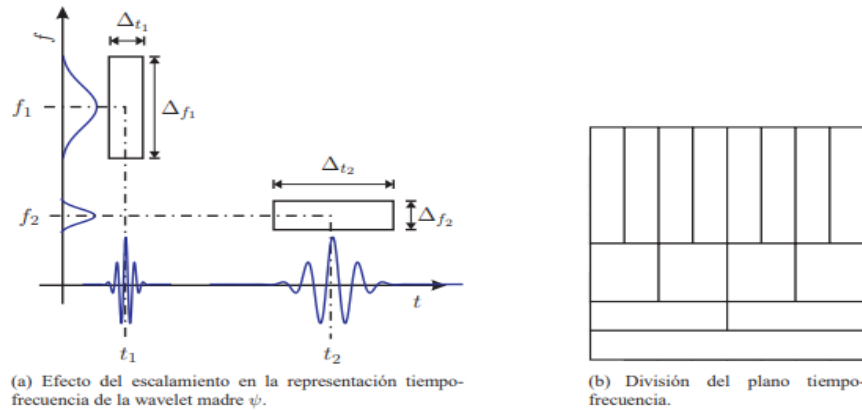
La división del plano tiempo-frecuencia no es uniforme, sin embargo, los átomos de análisis wavelet representados por los rectángulos en la Figura 8 mantienen un área constante, pues el principio de incertidumbre aún es aplicable en este caso [16].

Fig. 5. Representación gráfica de un escalograma con sus componentes Tiempo, Frecuencia, Amplitud.



Fuente: Autor

Fig. 6 Resolución de la Transformada Wavelet Discreta.



Fuente: A. Mertins, Signal analysis: Wavelets, filter banks, time-frequency transforms, and applications, 1999 p21.

El escalograma se obtiene a partir de la transformada wavelet continúa usando la expresión,

$$T_{SCAL}(t, a) = \frac{1}{Ca^2} |T_{CWT}(t, a)|^2 \quad (2.3.1)$$

En la cual el factor $\frac{1}{Ca^2}$ se inserta con el fin de normalizar la transformada, y la constante C se elige de tal forma que la energía obtenida en el escalograma sea igual a la energía total contenida en la señal, y finalmente se obtiene que $C = C\psi$ de la condición de admisibilidad en [17].

Con el fin de obtener una densidad tiempo-frecuencia a partir del escalograma, es necesario definir una frecuencia de referencia $f\psi$, la cual es la frecuencia central de la wavelet madre ψ , y se define la frecuencia f como:

$$f = \frac{f\psi}{a} \quad (2.3.2)$$

La densidad de tiempo y frecuencia, $T_{SCAL}(t, f)$ se obtiene a partir,

$$T_{SCAL}(t, f) df dt = T_{SCAL}(t, a) da dt \quad (2.3.3)$$

y finalmente:

$$\begin{aligned} T_{SCAL}(t, f) &= \frac{f\varphi}{f^2} T_{SCAL}(t, a = f\varphi/f) \\ &= \frac{1}{cf\varphi} |T_{CWT}(t, f\varphi/f)| \end{aligned} \quad (2.3.4)$$

2.6. Transformada por paquetes wavelet (WPT)


Es una variación de la Transformada Wavelet Discreta (DWT). Con la DWT se descompone la señal analizada en una serie de señales restringidas a ciertas bandas de frecuencia que forman una base del espacio de funciones, cumpliendo con propiedades como ortogonalidad, tamaño, localización y suavidad. La DWT busca obtener una representación tiempo-escala de una señal discreta. La descomposición se realiza a partir de funciones más complejas, en las cuales no se varía la frecuencia sino su posición y su escala temporal, estas funciones son conocidas como Wavelet Madre, que se correlacionan con las señales originales empleando una ventana variable. La definición de la DWT, está dada por (2.3.5), donde a y b son factores de escalamiento y traslación.

$$C(a, b) = \sum_{n \in \mathbb{Z}} f[n] \varphi_{j,k}[n] \quad (2.3.5)$$

$C(j, k)$ son coeficientes Wavelet diádicos, $f(n), n = 1 \dots N$ es una señal discreta y el factor diádico j, k construye la Wavelet Discreta. Los coeficientes Wavelet se obtienen con algoritmos de transformación piramidal (ver Fig. 7), que corresponde a un banco de filtros pasa-bajos y filtros pasa-altas, con un submuestreo de factor 2 en cada nivel del banco de filtros, a estos niveles se les conoce como niveles de descomposición. Los términos producidos tras la transformación son conocidos como coeficientes de aproximación y coeficientes de detalle [17].


Para acceder a una descomposición que represente de una manera más rica la señal analizada, la Transformada de Paquetes Wavelet descompone coeficientes normalmente no analizados, es decir los que parten de los detalles. Lo descrito se puede evidenciar claramente en la Fig. 7, donde los coeficientes de detalle de cada nivel no se descomponen, mientras los coeficientes de aproximación siguen siendo descompuestos nivel a nivel. En la Fig. 8 se evidencia la diferencia entre la DWT y WPT. Es claro que la utilización de los paquetes Wavelet propicia información que con la DWT no estaba disponible, información que puede incluir características discriminantes y facilita labores de clasificación. El contar con un mayor volumen de información también representa una desventaja frente a la Transformada Wavelet Discreta, porque se incrementa el costo computacional. Para disminuir los efectos de este fenómeno, se utilizan el algoritmo del Mejor Árbol, el cual identifica los nodos que contienen la información más relevante, valorando la entropía en cada uno de ellos con funciones o parámetros de cálculo. Los nodos se refieren a cada descomposición, en la Fig. 10, el bloque AA2 es un nodo, el bloque DD2 es otro nodo, los nodos AA2 y DD2 se encuentran en el mismo nivel de descomposición, es decir el segundo.

Fig.7: Algoritmo piramidal con DWT.




Autor: Documentación Matlab Discrete Wavelet Analysis p1-123

Fig.8: Algoritmo piramidal de 3 niveles con WPT -A Coeficientes de aproximación - Coeficientes de detalle.



Autor: Documentación Matlab Discrete Wavelet Analysis p1-123

Fig.9 Descomposición de la información



Autor: Documentación Matlab Discrete Wavelet Analysis p3-15

→ Se evidencia con mayor claridad cómo se descompone la información dependiendo el nivel que se desee extraer la información.

2.7. MFCC (Mel-Frequency Cepstral Coefficients)

Los parámetros MFCC son un tipo particular de coeficientes Cepstrales derivados de la aplicación del Cepstrum sobre una ventana de tiempo de la señal. Analizando el Cepstrum desde un punto de vista matemático, podemos decir que se trata de un operador que transforma una convolución en el tiempo en una suma en el dominio espectral. De esta forma se consigue separar de una forma elegante las dos componentes de información de la señal.

En general, el **Cepstrum** se define como la transformada inversa de Fourier del logaritmo del espectro de la señal de voz, es decir:

$$\text{Cepstrum}(s[n]) = \hat{s}[n] = F^{-1}[\log(|F[s[n]]|)] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log s(|s(e^{jw})|) dw \quad (2.3.6)$$

Donde $s[n]$

$$s[n] = e[n] * h[n] = \text{Convolución} \quad (2.3.7)$$


Se puede demostrar que después de la aplicación del Cepstrum, la convolución se transforma en una suma en el dominio Cepstral (por esta razón se considera al Cepstrum una transformación monomórfica):

$$\hat{s}[n] = \hat{e}[n] + \hat{h}[n] \quad (2.3.8)$$

Sin embargo, aunque casi todas las técnicas paramétricas de extracción de características de las señales basadas en ondas sonoras hacen el uso del Cepstrum, ésta raramente se utiliza directamente debido a su alta vulnerabilidad con los efectos del canal. Además, para mejorar la eficiencia del sistema, resultaría bastante útil intentar emular el comportamiento frecuencial del oído humano. De aquí surge el concepto de coeficientes MFCC que hacen uso de una nueva escala de frecuencia no lineal denominada MEL para imitar el comportamiento psicoacústico a tonos puros de distinta frecuencia dentro del oído humano. De hecho, estudios dentro de esta ciencia han demostrado que el sistema auditivo humano procesa la señal de voz en el dominio espectral, caracterizándose por tener mayores resoluciones en bajas frecuencias y esto es precisamente lo que se consigue mediante la escala MEL, asignar mayor relevancia a las bajas frecuencias de forma análoga a como se hace en el sistema auditivo humano.

2.7.1. Filterbank:

La señal se multiplica por un banco de filtros triangulares. Estos triángulos están espaciados de acuerdo con la escala de frecuencias MEL. Un ejemplo de este banco de filtros lo podemos ver en la siguiente figura:



Fuente: Documentación Matlab, Recuperado de <https://la.mathworks.com/help/audio/ref/mfcc.html>


Analizando la figura anterior, vemos que los puntos finales de cada filtro son definidos por las frecuencias centrales de los filtros adyacentes. En este caso concreto, el banco está formado por 20 filtros de los cuales, 10 están linealmente espaciados entre 100 y 1000 Hz, 5 logarítmicamente espaciados entre 1 y 2 kHz y otros 5 logarítmicamente espaciados entre 2 y 4 kHz. El ancho de banda de los filtros triangulares viene determinado por la distribución de la frecuencia de centro de cada filtro, siendo esta función de la frecuencia de muestreo y del número de filtros. Si el número de filtros en el banco aumenta, el ancho de banda de cada filtro decrece. Además, tal y como se mencionó anteriormente, el comportamiento del sistema psico-acústico humano se aproxima mediante la escala de frecuencias MEL:

$$Mel(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (2.3.9)$$

Donde f se corresponde con la frecuencia representada en el eje de escala lineal.

A continuación, hemos representado la escala de frecuencias MEL con respecto a la lineal para ilustrar gráficamente la relación entre ambas:

Fig. 11 Escala de frecuencias de MEL



Fuente: Zhang, Peiwei & Sui, Xin. (2017). Application of Digital Music Technology in Music Pedagogy, p4.

Adicional existe también los valores de Delta y Delta-Delta, que no serán parte de la información de entrenamiento ya que este enfoque es más para la predicción a partir de la voz humana, siendo el primero el que indica que cambio ahí de un coeficiente a otro y el segundo con qué velocidad se realiza este cambio.

3. ALGORITMOS DE CLASIFICACIÓN

❖ Máquinas de aprendizaje

De forma concreta, las Máquinas de aprendizaje, trata de crear algoritmos capaces de generalizar comportamientos y reconocer patrones a partir de una información suministrada. Es, por lo tanto, un proceso de inducción del conocimiento.

Una definición relativamente general de aprendizaje dentro del contexto humano podría ser: proceso a través del cual se adquieren o modifican habilidades, destrezas, conocimientos, conductas o valores como resultado del estudio, la experiencia, la instrucción, el razonamiento y la observación. De esta definición es importante hacer notar que el aprendizaje debe producirse a partir de la experiencia con el entorno, no se considera aprendizaje toda aquella habilidad o conocimiento que sean innatos en el individuo o que se adquieran como resultado del crecimiento natural de éste. Siguiendo un esquema similar, se considera aprendizaje a aquello que la máquina pueda aprender a partir de la experiencia, no a partir del reconocimiento de patrones programados a priori. Por tanto, una tarea central de cómo aplicar esta definición al contexto de la computación consiste en alimentar la experiencia de la máquina por medio de objetos con los que entrenarse (ejemplos) para, posteriormente, aplicar los patrones que haya reconocido sobre otros objetos distintos.

Hay un gran número de problemas que caen dentro de lo que llamamos máquinas de aprendizaje. La principal diferencia entre ellos estriba en el tipo de objetos que intentan predecir. Algunas clases habituales son:

- **Regresión:** Intentan predecir un valor real. Por ejemplo, predecir el valor de la bolsa mañana a partir del comportamiento de la bolsa que está almacenado (pasado). O predecir la nota de un alumno en el examen final basándose en las notas obtenidas en las diversas tareas realizadas durante el curso.
- **Clasificación** (binaria o multiclase): Intentan predecir la clasificación de objetos sobre un conjunto de clases prefijadas. Por ejemplo, clasificar si una determinada noticia es de deportes, entretenimiento, política, etc. Si solo se permiten 2 posibles clases, entonces se llama clasificación binaria; sí se permiten más de 2 clases, estamos hablando de clasificación multiclase.
- **Ranking:** Intentar predecir el orden óptimo de un conjunto de objetos según un orden de relevancia predefinido. Por ejemplo, el orden en que un buscador devuelve recursos de internet como respuesta a una búsqueda de un usuario.

Normalmente, cuando se aborda un nuevo problema, lo primero que se hace es enmarcarlo dentro de alguna de las clases anteriores, ya que dependiendo de cómo se clasifique será la forma en que podemos medir el error cometido entre la predicción y la realidad.

Por otra parte, y dependiendo del tipo de salida que se produzca y de cómo se aborde el tratamiento de los ejemplos, los diferentes algoritmos se pueden agrupar en:

- **Aprendizaje supervisado:** se genera una función que establece una correspondencia entre las entradas y las salidas deseadas del sistema, donde la base de conocimientos del sistema está formada por ejemplos etiquetados a priori (es decir, ejemplos de los que sabemos su clasificación correcta). Un ejemplo de este tipo de algoritmo es el problema de clasificación al que hemos hecho mención anteriormente.
- **Aprendizaje no supervisado:** donde el proceso de modelado se lleva a cabo sobre un conjunto de ejemplos formados únicamente por entradas al sistema, sin conocer su clasificación correcta. Por lo que se busca que el sistema sea capaz de reconocer patrones para poder etiquetar las nuevas entradas.
- **Aprendizaje semi-supervisado:** es una combinación de los dos algoritmos anteriores, teniendo en cuenta ejemplos clasificados y no clasificados.
- **Aprendizaje por refuerzo:** en este caso el algoritmo aprende observando el mundo que le rodea y con un continuo flujo de información en las dos direcciones (del mundo a la máquina, y de la máquina al mundo) realizando un proceso de ensayo-error, y reforzando aquellas acciones que reciben una respuesta positiva en el mundo.

→ **Transducción:** es similar al aprendizaje supervisado, pero su objetivo no es construir de forma explícita una función, sino únicamente tratar de predecir las categorías en las que caen los siguientes ejemplos basándose en los ejemplos de entrada, sus respectivas categorías y los ejemplos nuevos al sistema. Es decir, estaría más cerca del concepto de aprendizaje supervisado dinámico.

→ **Aprendizaje multitarea:** engloba todos aquellos métodos de aprendizaje que usan conocimiento previamente aprendido por el sistema de cara a enfrentarse a problemas parecidos a los ya vistos.

Para interés de este documento se utilizará Aprendizaje supervisado.

Algunos de los algoritmos más usados frecuentes en aprendizaje supervisado:

1. Árboles de decisión.
2. Clasificación de Naïve Bayes.
3. Regresión por mínimos cuadrados.
4. Regresión Logística.
5. Máquinas de soporte vectorial (SVM).
6. Métodos "Ensemble" (Conjuntos de clasificadores).
7. Redes Neuronales.

❖ Árboles de decisión

Un árbol de decisión [18] es un modelo de predicción utilizado en diversos ámbitos que van desde la inteligencia artificial hasta la Economía. Dado un conjunto de datos se fabrican diagramas de construcciones lógicas, muy similares a los sistemas de predicción basados en reglas, que sirven para representar y categorizar una serie de condiciones que ocurren de forma sucesiva, para la resolución de un problema.

❖ Clasificación de Naïve Bayes.

En términos simples, un clasificador de Bayes ingenuo asume que la presencia o ausencia de una característica particular no está relacionada con la presencia o ausencia de cualquier otra característica, dada la clase variable. Por ejemplo, una fruta puede ser considerada como una manzana si es roja, redonda y de alrededor de 7 cm de diámetro. Un clasificador de Bayes ingenuo considera que cada una de estas características contribuye de manera independiente a la probabilidad de que esta fruta sea una manzana, independientemente de la presencia o ausencia de las otras características.

Para otros modelos de probabilidad, los clasificadores de Bayes ingenuo se pueden entrenar de manera muy eficiente en un entorno de aprendizaje supervisado. En

muchas aplicaciones prácticas, la estimación de parámetros para los modelos Bayes ingenuo utiliza el método de máxima verosimilitud, en otras palabras, se puede trabajar con el modelo ingenuo de Bayes sin aceptar probabilidad bayesiana o cualquiera de los métodos bayesianos.

❖ **Regresión por mínimos cuadrados.**

Es una técnica de análisis numérico enmarcada dentro de la optimización matemática, en la que, dados un conjunto de pares ordenados —variable independiente, variable dependiente— y una familia de funciones, se intenta encontrar la función continua, dentro de dicha familia, que mejor se aproxime a los datos (un "mejor ajuste"), de acuerdo con el criterio de mínimo error cuadrático.

En su forma más simple, intenta minimizar la suma de cuadrados de las diferencias en las ordenadas (llamadas residuos) entre los puntos generados por la función elegida y los correspondientes valores en los datos. Específicamente, se llama mínimos cuadrados promedio (LMS) cuando el número de datos medidos es 1 y se usa el método de descenso por gradiente para minimizar el residuo cuadrado. Se puede demostrar que LMS minimiza el residuo cuadrado esperado, con el mínimo de operaciones (por iteración), pero requiere un gran número de iteraciones para converger.

❖ **Regresión Logística.**


Es una técnica de análisis numérico enmarcada dentro de la optimización matemática, en la que, dados un conjunto de pares ordenados —variable independiente, variable dependiente— y una familia de funciones, se intenta encontrar la función continua, dentro de dicha familia, que mejor se aproxime a los datos (un "mejor ajuste"), de acuerdo con el criterio de mínimo error cuadrático.

En su forma más simple, intenta minimizar la suma de cuadrados de las diferencias en las ordenadas (llamadas residuos) entre los puntos generados por la función elegida y los correspondientes valores en los datos. Específicamente, se llama mínimos cuadrados promedio (LMS) cuando el número de datos medidos es 1 y se usa el método de descenso por gradiente para minimizar el residuo cuadrado. Se puede demostrar que LMS minimiza el residuo cuadrado esperado, con el mínimo de operaciones (por iteración), pero requiere un gran número de iteraciones para converger [19].

❖ Máquinas de soporte vectorial (SVM).

Con las máquinas de soporte vectorial, se hace una transformación no lineal (Φ) a priori del espacio de entrada, a un espacio de características de dimensión mayor, donde posiblemente los datos pueden ser tratados de forma lineal, la Fig. 12 ilustra un poco este proceso [20].

Fig. 12 Transformación no lineal a priori del espacio de entrada al espacio de características.



Fuente: Alejandro J. Orozco-Naranjo Detection of Pathological and Normal Heartbeat Using Wavelet Packet, Support Vector Machines and Multilayer Perceptron Tecno.Lógicas., p 74.

Las máquinas de soporte vectorial son entrenadas a través del principio de inducción de minimización del riesgo estructural, con el que se ha logrado implementar algoritmos de aprendizaje que parametrize la habilidad de generalización de las máquinas de soporte vectorial, lo que ha permitido establecer un margen máximo de separación entre las clases, además de hallar una superficie de separación entre las clases, que propicien un intervalo de confianza óptimo para el grupo de funciones clasificadoras obtenidas en el proceso de entrenamiento; esto a diferencia del perceptrón multicapa que es entrenado a través del principio de minimización del riesgo empírico y donde se busca la generalización a través de lograr un mínimo error de entrenamiento.

❖ Redes Neuronales (Perceptrón Multicapa (MLP)).

El MLP es el estándar de una red neuronal artificial usada para un amplio rango de tareas, los modelos de neuronas de las MLP (Perceptrón Multicapa) son perceptrones estándares, pero su función de activación no es una función umbral o inicio lineal sino una función lineal con un gradiente. Un método muy popular de entrenamiento a través de MLP es el backpropagation o la regla de delta generalizada. El valor actual de la salida del perceptrón multicapa es calculada utilizando (3.1.1):

$$y_{pj} = f(\sum_{i=0}^{n-1} w_i * x_i) \quad (3.1.1)$$

Los errores de clasificación del MLP son propagados desde la capa de salida a la capa de entrada, que se conoce como backpropagation. La tasa de aprendizaje debe ser más grande que cero y no mayor a uno [21].


❖ Métodos “Ensemble” (Métodos combinados de aprendizaje).

En el campo del aprendizaje automático, los métodos combinados (métodos de ensemble) utilizan múltiples algoritmos de aprendizaje para obtener un rendimiento predictivo que mejore el que podría obtenerse por medio de cualquiera de los algoritmos de aprendizaje individuales que lo constituyen.

La idea de los métodos combinados es considerar múltiples hipótesis simultáneamente para formar una hipótesis que, con suerte (y la ayuda de algunos teoremas esenciales), se comporte mejor. El término de métodos de ensemble se suele reservar para aquellas combinaciones que hacen uso de múltiples hipótesis pertenecientes a una misma familia, mientras que se usa el término más general de sistemas de aprendizaje múltiples cuando las hipótesis que se combinan provienen de diversas familias.

Una combinación de algoritmos de aprendizaje supervisado es en sí mismo un algoritmo de aprendizaje supervisado y puede ser entrenado y usado para hacer predicciones. Sin embargo, se debe tener en cuenta que una combinación de hipótesis (algoritmos) de una determinada familia no es necesariamente una hipótesis (algoritmo) de la misma familia, por lo que podríamos obtener mejores resultados que con los elementos individuales de la familia, aunque también podemos correr el riesgo de obtener un modelo sobre ajustado si no se tienen algunas precauciones. En la práctica, la forma en que se seleccionan los modelos individuales que se combinan hacen uso de algunas técnicas que tienden a reducir los problemas relacionados con el exceso de ajuste de los datos de entrenamiento y mejoran la predicción conjunta.

Fig.13 Promedio de 100 suavizantes, cada uno ajustado a un subconjunto del conjunto de datos original, llegamos a un predictor embolsado (línea roja).



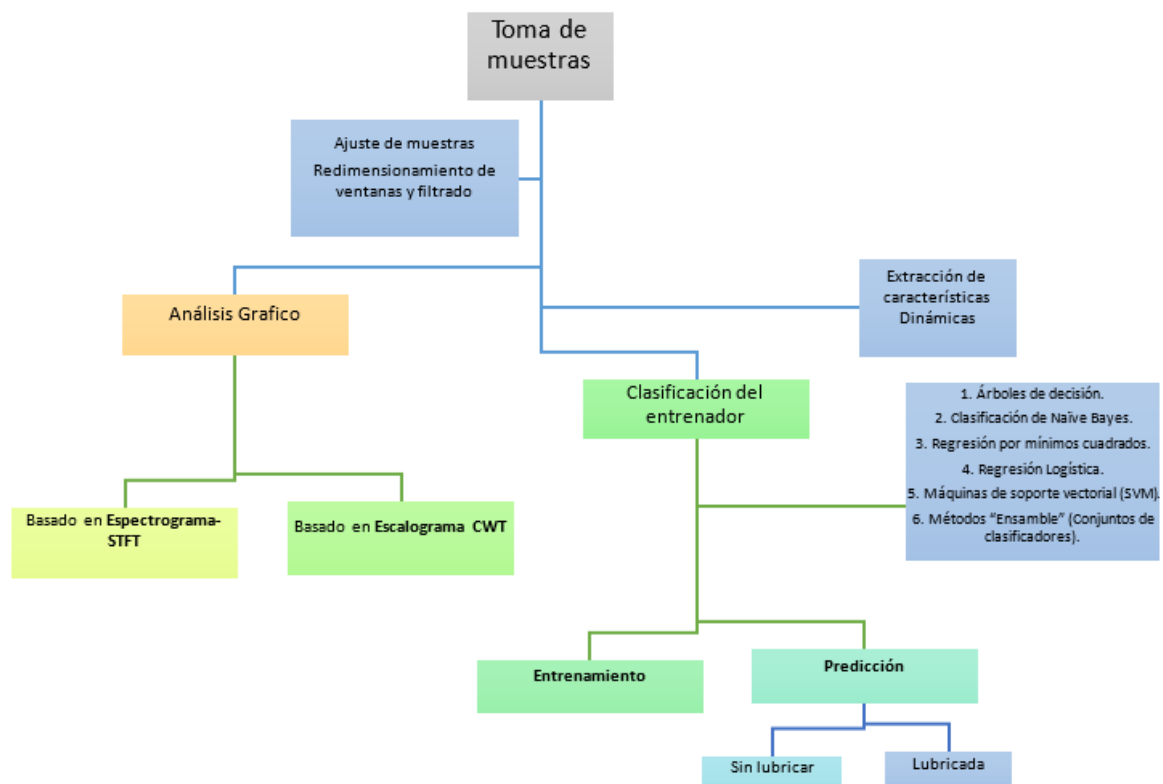
Fuente: Autor

4. Marco experimental

Para aplicar el análisis tiempo-frecuencia al reconocimiento de patrones en señales de audio, es necesario diseñar una metodología experimental para el desarrollo del sistema, que permita la caracterización de las señales y su mapeo en vectores de características que puedan servir de entrada a un clasificador mediante el cual se obtenga una salida que permita diferenciar las observaciones pertenecientes a diferentes clases, las cuales para este caso pueden ser la señal, Cadena Lubricada o Sin lubricar o en su defecto, una etiqueta de dos componentes, cero para no lubricada y uno para lubricada, de este modo se parte la agrupación binaria, realizando la identificación, infiriendo a cuál grupo pertenecen las muestras.

La metodología llevada a cabo para el desarrollo del sistema, en este trabajo se compone de cuatro partes principales: Preprocesamiento de la señal, estimación de las representaciones tiempo-frecuencia, extracción de características dinámicas y por último la fase de clasificación. La Figura 14 muestra el esquema de la metodología experimental.

Fig. 14 Metodología Organigrama.

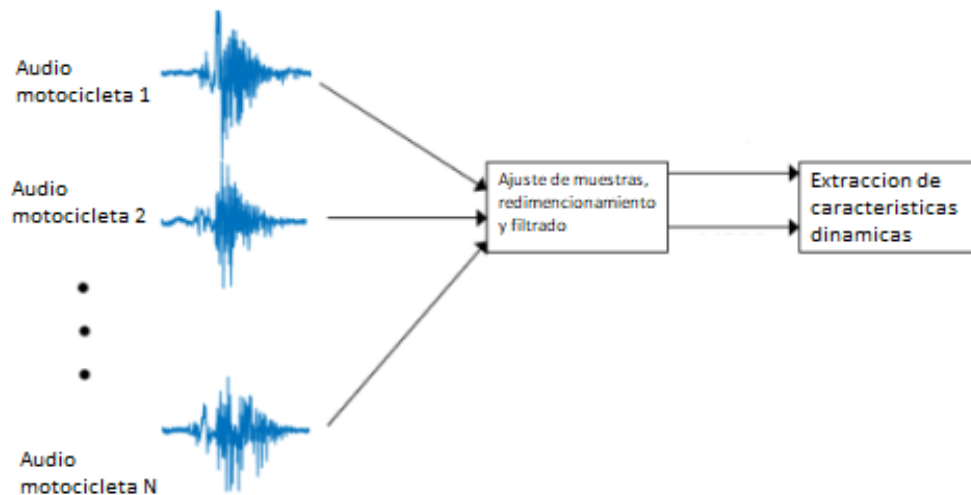


Fuente: Autor

La primera fase es la de adecuar la señal a la metodología. Esta fase es completamente dependiente de la aplicación, pues depende del tipo de señal que se tenga y del equipo con el cual se adquiere, se pueden necesitar procedimientos de re-muestreo, de filtrado, segmentación y de qué tan relevantes pueden terminar

siendo los datos después de este reajuste. Por otro lado, el rango dinámico de las señales es diferente dependiendo del tipo y la naturaleza de la señal, pues mientras algunas miden la actividad eléctrica directamente (como la señal electrocardiográfica), otras señales miden la actividad mecánica, la cual se refleja en ondas sonoras y vibraciones que son captadas mediante micrófonos (este es el caso para la señal de audio, y el comportamiento del sistema mecánico del tren trasero de la motocicleta).

Fig. 15 Ajuste de las muestras y extracción de características.



Fuente: Autor

Después de la toma de las muestra se procede a realizar validación de su dimensionalidad, ajustando un número de igual dimensión de la señal, siendo estas de alrededor de 10 segundos, y alcanzando cada muestra a tomar la dimensión de 500.000 datos, estos se ajustaron, para que todas las muestras que tuvieran exactamente, cada una, 100.000 datos para así asegurar que cumplieran la condición de dimensionalidad para todas las muestras, posterior a esto se evidencio que las primeras 15.000 muestras aproximadamente, ya que este valor varía en cada muestra, representaba un valor absoluto igual a cero, por ende se procedió a realizar la eliminación de estas, ya que no representaban un valor significativo relevante. El siguiente paso de la metodología planteada, se refiere a la implementación de dos transformaciones de espacio, pertenecientes a la transformada de Fourier y la transformada Wavelet Continua de la clase afín. Algunas de estas distribuciones tienen uno o más parámetros que se deben ajustar en sus kernels, los cuales manejan variables como reducción de términos cruzados y resolución. Luego, el siguiente paso involucra el cálculo de parámetros variantes en el tiempo, estas variables o características dinámicas también tienen parámetros que se deben ajustar dependiendo de la señal que se está analizando.

La validación de la relevancia de las características se realiza con base en el rendimiento de clasificación, ya que se utilizarán el aplicativo de Classification Learner de Matlab y de estos se tomarán los diez algoritmos que mayor porcentaje

de clasificación realicen, ya que en un entrenamiento utiliza 23 diferentes algoritmos, así su rendimiento depende de la estructura de los datos siendo esta la última etapa.

4.1. Cálculo de representaciones tiempo-frecuencia

Las representaciones tiempo-frecuencia permiten un mapeo bidimensional de la señal bajo análisis, permitiendo reconocer de forma evidente algunas características que son útiles para diferenciar un tipo de señal de otra. Como ya se mencionó anteriormente, se utilizarán Espectrograma a partir de la STFT, Escalograma a partir de la CWT, la cual pertenece a la clase afín.

Estas distribuciones tienen parámetros para ajustar. Así, el parámetro del espectrograma es la ventana de análisis en el tiempo (tipo y longitud). En todas las pruebas se utilizará una ventana de tipo Hamming para el análisis, ya que es el tipo de ventana más usado para el cálculo de esta representación [24]. La elección de la longitud de la ventana depende fuertemente del contenido espectral de la señal que se está analizando. De esta forma, la ventana debe ser lo suficientemente corta como para permitir una buena resolución en el dominio del tiempo, y al mismo tiempo debe ser lo suficientemente larga para contener por lo menos un periodo de la componente de menor frecuencia de la señal bajo análisis [25].

Teniendo en cuenta el espectrograma como referencia, con éste es posible obtener una representación aceptable de la señal, la cual puede dar una noción de la estructura de las componentes y de su ubicación en el plano tiempo-frecuencia.

El escalograma involucra el cálculo de la CWT, la cual requiere especificar la onda madre con la cual se realiza la descomposición. Para este caso se elige la wavelet madre Morlet, pues la CWT es altamente redundante y no requiere de una base ortogonal. La wavelet Morlet se construye multiplicando una función gaussiana por una senoide de la frecuencia analizada. Esta onda madre es flexible en resolución de tiempo y escala, ya que la localización en el tiempo se puede cambiar al modificar la longitud de la función gaussiana, independientemente de su frecuencia de oscilación. Cuando se usa la wavelet Morlet, la conversión entre escala y frecuencia es simple e intuitiva.

4.2. Extracción de características dinámicas

Los coeficientes Cepstrales son aproximaciones, pues dividen el espectro de frecuencia en un número determinado de bandas. De esta forma, el parámetro principal de esta aproximación, es el número de filtros del banco, que se aplica a la TFD para separar cada una de las bandas de interés, además, se debe determinar la forma adecuada de los filtros y su solapamiento en el dominio de la frecuencia.

Para el cálculo de coeficientes Cepstrales se utilizan filtros distribuidos según la escala Mel, si el espectro de la señal a analizar se encuentra dentro del rango

auditivo humano; de lo contrario, se distribuyen linealmente. Se utilizan filtros triangulares, con un solapamiento de 50 % y una cantidad constante de 14 filtros. Para este caso el número de coeficientes Cepstrales que se toman, son 14, siendo el número adecuado para obtener una buena precisión en la clasificación.

4.3. Preprocesamiento de la señal

Inicialmente se había pensado trabajar en el rango de ultrasonido para así poder eliminar la componente de bajas frecuencias, eliminando así posible ruido de una manera inicial, pero como los micrófonos de ultrasonido aún son una tecnología incipiente en cuanto a divulgación y implementación, dando así un difícil acceso por la falta de información que se tiene.

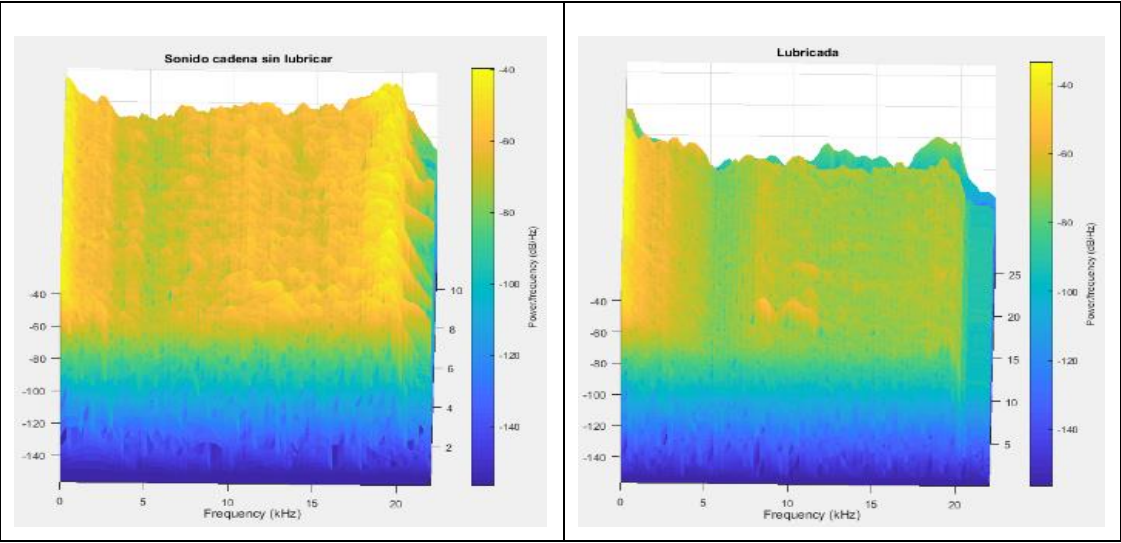
La solución que surge a raíz de la determinación empírica del manejo de la motocicleta como usuario de esta, surge de que se ha determinado que existe un cambio en el comportamiento sonoro de la cadena cuando esta presenta la condición de falta de lubricante la toma de las muestras en el rango de 50 Hz a 20 kHz aproximadamente con un el micrófono de un Smartphone de marca Samsung tipo MEMS (**Sistemas microelectromecánicos**) de referencia Knowles S4.10 el cual integra dos membranas internas para incorporar un sonido estéreo, esto se ve representado en dos canales, es decir la muestra o el audio grabado tendría dos canales de información, para fines de este proyecto se elimina uno de esos canales.

El archivo generado es tipo M4A, siendo la abreviatura de MPEG-4 parte 14 y constituye un tipo de archivo creado por Apple en 2004 a partir del formato de archivo QuickTime. Los archivos M4A constituyen una mejora de los archivos MP3, básicamente debido a su capacidad para ofrecer una compresión sin pérdida. posterior a la obtención de las muestras las cuales corresponden a 10 motocicletas, 10 audios sin lubricar la cadena y 10 con la cadena lubricada para un total de 20 muestras, se procede a realizar la conversión a .wav (apócope de WAVE form audio file format), es un formato de audio digital normalmente sin compresión de datos, admite archivos mono y estéreo a diversas resoluciones y velocidades de muestreo, la finalidad de esta conversión es la de obtener la información sin ninguna compresión o pérdida de datos, obteniendo así la mejor precisión en los datos, al validar esto se tiene un vector columna con una dimensión aproximada de 1 a 500.000 valores, que es lo que corresponde aproximadamente a 10 segundos de grabación. Por cuestiones de procesamiento se decide disminuir la muestra a un vector de 100.000 datos.

Como datos de prueba #1, dependiendo de su tiempo de respuesta se pasará a realizar las pruebas correspondientes con el número total de datos, posterior se procede a realizar un análisis inicial del comportamiento en la frecuencia, ayudándonos de la transformada de Fourier y la de Wavelet, en la figura 17 se puede apreciar al lado derecho el comportamiento espectral con la transformada de Fourier de una muestra, al lado derecho sin lubricar y al lado izquierdo lubricada, en la figura


18 se presenta el resultado del comportamiento representado en el escalograma, donde se evidencia mayor resolución lo que se traduce en mayor precisión en la información, una analogía de esto, que puede llegar a ser más clara podría ser con la calidad en una fotografía entre más información tengas (Mas pixeles) mayor serán los detalles en la imagen.

Fig. 16 Espectrograma del comportamiento de una muestra sin lubricar (Izquierda) y lubricada (Derecha).



Fuente: Autor

Fig. 17 Escalograma del comportamiento de una muestra sin lubricar (Izquierda) y lubricada (Derecha).



Fuente: Autor


4.4. Wavelet, Filtrado, Escala o Resolución.

El parámetro scale (s) usado en el análisis Wavelet es similar a la escala usada en la confección de mapas. Como en el caso de los mapas, las escalas grandes corresponden a vistas globales (no detalladas) mientras que escalas más pequeñas corresponden a vistas más detalladas. Similarmente, en términos de frecuencia, las bajas frecuencias (altas escalas) corresponden a la información global de una señal (es decir, lo que generalmente marca la tendencia de la señal), mientras que las altas frecuencias (bajas escalas) corresponden a información detallada de patrones ocultos de la señal (los que usualmente tienen una duración reducida de tiempo), esto es de gran utilidad para así poder escoger el nivel de donde se desea es mucho más relevante la información, los parámetros que se establecieron para elegir una función Wavelet, será la Wavelet madre y servirá como prototipo para todas las ventanas que se emplean en el proceso. Existe una importante cantidad de familias de funciones Wavelets que han probado ser especialmente útiles; entre ellas destacan la Haar, Daubechies entre las más importantes, la Biortogonal, una wavelet donde la transformada de wavelet asociada es invertible pero no necesariamente ortogonal.

El diseño de wavelets Biortogonales permite más grados de libertad que las wavelets ortogonales. Un grado adicional de libertad es la posibilidad de construir funciones wavelet simétricas, esta condición es una de las razones por la que fue seleccionada, este paso es importante ya que al ser aplicado se terminan teniendo una mejor resolución de la información, lo que puede ser interpretado como mejor calidad de la muestra, en la siguiente figura de su representación correspondiente bajo el análisis gráfico en tiempo-frecuencia se puede dar una mejor interpretación del cambio significativo, cabe decir que se escogió un primer nivel de detalle en la reconstrucción de la señal, ya que este era el que mejor se acercaba a una mejora de calidad en los datos ya que si se aplicaba un segundo, o tercer nivel se percibía que la información se veía afectada, de manera negativa perdiendo calidad y distorsionando la misma.


La siguiente gráfica se puede evidenciar el comportamiento y el cambio que se obtiene en la señal:

Fig. 18 Filtrado de la señal Completa.




Fuente: Autor

Fig. 19 Filtrado de la señal a detalle primeros Mil datos




Fuente: Autor

Fig. 20 Superior Izq. muestra de cadena sin lubricar, Superior Der. lubricada.



Fuente: Autor

Fig. 21 Correspondientes filtradas



Fuente: Autor

- Las gráficas de los Espectrogramas y Escalogramas de las señales, serán presentadas en los apéndices A y B respectivamente.

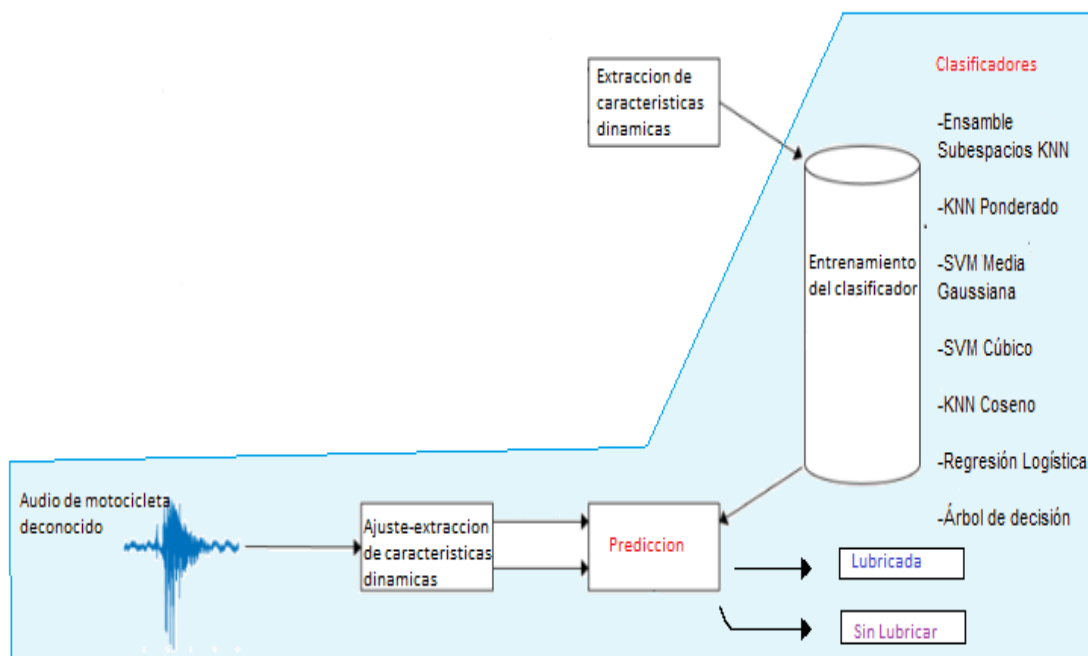
4.5. Extracción Coeficientes en la escala de Mel.

Se crea una tabla donde son almacenados los Coeficientes que va de MFCC 1 a MFCC 14 creando una matriz de 3800 x 14 (76.000) aproximadamente cuando inicialmente la totalidad de datos que comprenden las 20 muestras eran 1`700.000 datos en total, dándose una reducción significativa en los datos y el procesamiento, posterior a la reducción se procede a aplicar una etiqueta binaria asignándole un cero a los datos de las muestras sin lubricar y uno a las muestras lubricadas para así pasar a la etapa de clasificación, adicional se creó un archivo, donde se agrupaban el 70 % de los datos de entrenamiento y el 30% restante se creó en archivos individuales para cada matriz de datos de pruebas, es decir para una muestra que esta etiquetada como muestra lubricada en el nombre de archivo, internamente no tendrá el target con su correspondiente equivalencia binaria, la cual si tienen los datos de entrenamiento, esto será explicado a profundidad en la parte de validación.

4.6. Clasificación

En la siguiente figura se indica cómo será la fase de clasificación la cual comprende el entrenamiento con las características extraídas de los datos tomados en la fase anterior

Fig. 22 Fase de clasificación.



Fuente: Autor.

En la siguiente tabla se puede evidenciar la precisión, tiempo de procesamiento en segundos y la velocidad de procesamiento de los algoritmos de clasificación que mejor porcentaje de acierto tuvieron en su etapa de entrenamiento:

Tabla 1 Características de Clasificación

Tipo de Clasificador	Ensamble Subespacios KNN	KNN Ponderado	SVM Media Gaussiana	SVM Cúbico	KNN Coseno	Regresión Logística	Árbol de decisión
Precisión	90.8%	89,60%	88,90%	88%	88,30%	81,90%	81,20%
Tiempo Segundos	35,308	18,904	41,862	44,617	26,577	44,909	30,929
Velocidad	890 obs/sec	~3900 obs/sec	~6900 obs/sec	~7200 obs/sec	~3100 obs/sec	~8200 obs/sec	~3600 obs/sec


Fuente: Autor

Cabe destacar que, aunque el clasificador de ensamble por subespacios por el método K vecinos más cercanos es el que mayor porcentaje de acierto tiene, su tiempo de procesamiento estaría en el puesto cuatro ya que demora aproximadamente 36 segundo los cuales para, aplicaciones donde la velocidad de procesamiento versus tiempo sean las más adecuadas, y generen una limitante, podría verse afectado, generando demoras en el procesamiento o retrasos en la información dando una respuesta lenta. Para trabajo futuro se puede realizar la validación cual es el algoritmo que mejor rendimiento tiene en relación tiempo, velocidad y precisión y así se podría determinar cuál se pueda implementar en un sistema embebido.

4.7. Matriz de Confusión

Una matriz de confusión es una herramienta que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. Uno de los beneficios de las matrices de confusión es que facilitan ver si el sistema está clasificando erróneamente dos clases, en este caso en la figura 22 se muestra la matriz de confusión del algoritmo de Ensamble en Subespacios KNN, mostrando cuales erróneamente fueron predecías como positivas y cuales como negativas, dándonos 4 valores, los valores en verde indican las predicciones correctas, tanto para la clase 0 o no lubricada, como para la clase 1 que sería la lubricada, en este caso, las predicciones correctas de los 1900 datos ingresados, indican 829 correctamente como no lubricados y 121 como no lubricados a valores que corresponden como lubricados, 876 como si lubricados con la etiqueta 1 y 74 como no lubricados que correspondían a lubricados.

Fig.23 Matriz de confusión de modelo Ensamble Subespacios KNN.



Fuete: Autor.

Fig. 24 Gráfica en porcentajes equivalentes a los datos suministrados en la gráfica 21.




Fuente: Autor.

4.8. Curva Roe

Una curva ROC (acrónimo de Receiver Operating Characteristic, o Característica Operativa del Receptor) es una representación gráfica de la sensibilidad frente a la especificidad para un sistema clasificador binario según se varía el umbral de discriminación. Otra interpretación de este gráfico es la representación de la razón o ratio de verdaderos positivos (VPR = Razón de Verdaderos Positivos) frente a la razón o ratio de falsos positivos (FPR = Razón de Falsos Positivos) también según se varía el umbral de discriminación (valor a partir


del cual decidimos que un caso es un positivo). en la figura 23 se puede evidenciar que a partir de los valores 0.13,0.92 sería el punto de clasificación para la etiqueta 1 qué es la etiqueta de lubricada y para la no lubricada que se muestra en la figura 24 el valor es 0.08,0.84 para la predicción de no lubricada

Fig.25 Curva ROC del modelo Ensamble Subespacios KNN Predicción Lubricada.



Fuente: Autor

Fig.26 Curva ROC del modelo Ensamble Subespacios KNN Predicción No Lubricada



Fuente: Autor.

- Las gráficas de los otros seis modelos, Matriz de confusión y curva ROE, serán mostradas en los apéndices C y D respectivamente.

5. Validación.

El análisis de las tablas 2.a – 2.b, la cuales registran la validación de seis muestras en los 7 algoritmos que mejor rendimiento presentaron con la clasificación basada en MFCC, las 6 muestras son de 3 tipos de motocicletas de diferentes modelos, Tipo enduro, Sport y Noked, las cuales presentan un nivel de desgaste en el mismo orden

de leve, moderado y alto respectivamente, estas mismas consideraciones se tuvieron con las muestras de entrenamiento.

Tabla 2.A Validación de los algoritmos de Clasificación.

Tipo de Clasificador	KNN Coseno			Regresión Logística			Árbol de decisión		
Precisión	88,30%			81,90%			81,90%		
Validación									
Moto prueba #	1	2	3	1	2	3	1	2	3
Sn lubricar	0.3422	0.0711	0.3170	0.3956	0.1511	0.5134	0.3378	0.1111	0.5268
Lubricada	0.9067	0.9378	0.5491	0.9244	0.8400	1	0.8800	0.8044	0.7098

Fuente: Autor

Tabla 2.B Validación de los algoritmos de Clasificación.

Tipo de Clasificador	Ensamble Subespacios KNN			KNN Ponderado			SVM Media Gaussiana			SVM Cúbico		
Predicción	90,80%			89,60%			88,90%			88%		
Validación												
Moto prueba #	1	2	3	1	2	3	1	2	3	1	2	3
Sn lubricar	0.4311	0.0400	0.4554	0.4311	0.0578	0.5268	0.1556	0.0178	0.0714	0.3156	0.0533	0.6830
Lubricada	0.9511	0.8933	0.8214	0.9289	0.9022	0.7098	0.5333	0.6400	0.0179	0.8844	0.8933	0.8080

Fuente: Autor

EL resultado de la predicción de cada algoritmo era un vector columna de 0 y 1, emulando a las etiquetas que ya habíamos predefinido en las muestras de entrenamiento, cada muestra se procesó de manera independiente generando su propia matriz con los correspondientes 14 MFCC por 226, en un archivo Excel, y al ser pasados por el predictor arrojará el vector columna de respuesta, para llegar a un valor más interpretable, se procedió a realizar la sumatoria de todos los valores y dividirlos por el tamaño total de la muestra, dando el valor promedio en 5.1.

$$\tilde{x} = \frac{\sum x_i}{n_i} \quad (5.1.)$$

Este valor tiene un rango de 0 a 1, siendo este un valor altamente variante y como lo que se desea en una respuesta con un valor fijo, se procede a utilizar aproximaciones, a partir de un valor medio entre 0 y 1, el cual es 0.5 realizando el

siguiente sesgo:

$$SI\ n > 0.5 = Lubricada$$

$$SI\ n < 0.5 = No\ Lubricada$$

Esta condición permitirá realizar agrupaciones y así aumentar el rango de clasificación, por lo anterior se llegan a las siguientes afirmaciones basándonos en las tablas 2.a y 2.b.:

- El clasificador de Ensamble por Subespacios KNN (K vecinos más cercanos) junto con el KNN por Coseno son los algoritmos que acertaron en las 3 muestras de clasificación.
- La muestra de la tercera moto, tanto para lubricada como no lubricada, presento problemas de clasificación, ya que, para las muestras sin lubricar, sobrepasaron el valor de 0.5 entrando en el rango de lubricadas en los clasificadores KNN Ponderado, SVM Cúbico, Regresión Logística y Árbol de decisión sobre paso el umbral indicando siendo el que mayor problema de clasificación presento, se valida las muestras bajo análisis auditivo y se evidencia que la diferencia auditiva entre lubricada y no lubricada es muy pequeña y por lo cual se presenta este error de clasificación.

6. Discusión Y Conclusiones

El presente proyecto de grado tuvo como objetivo comprobar que se puede realizar una correcta detección de la falta de lubricación en el tren trasero de una motocicleta, a partir de las características extraídas de su comportamiento sonoro, ya que inicialmente la premisa que se tenía, apoyado en la lubricación basada en ultrasonidos, es que, bajo este método, se elimina el ruido de baja frecuencia o, en otras palabras, toda la información no relevante por debajo de los 20 kHz.

Pero a partir de los problemas de conseguir un micrófono que nos permitiera grabar por encima de esta frecuencia, ya que actualmente existe este tipo de tecnología, la información para su implementación aún sigue estando limitada para la banda de 20 kHz ya que es donde mayor aplicabilidad se tiene, y por encima de esta, su uso, es estrictamente de uso industrial, por ende, su costo es elevado dificultando aún más su implementación.

Para los alcances de este proyecto, al encontrarnos con estas barreras, se decide apoyar una teoría, la cual partía de la premisa de observación como usuario de motocicleta, que a partir de que la cadena ya no contenía lubricante en su estructura, esta empezaba a tener un sonido característico, el cual se pudo detectar con el sistema auditivo humano, indicando, que las componentes principales están en el rango audible, de acuerdo a Olarte, W., & Botero, el ultrasonido presenta mejores características para detectar fallas en rodamientos, los cuales por su configuración física presentan condiciones sonoras superiores al rango audible.

Para encontrar estas diferencias en el comportamiento sonoro de estos dos sistemas mecánicos se realizó un análisis aplicando procedimientos matemáticos como el espectrograma y el escalograma, estas observaciones se evidencian en las gráficas 17 y 18, dando así validación a esta hipótesis, posterior a esto se procedió a realizar la extracción de los coeficientes Cepstrales en la escala de Mel, en este, se presentaron las dudas de si servía como método de extracción de información, ya que al realizar un análisis más a fondo se encontraba que el banco de filtros tienen un límite máximo hasta los 7 kHz, como se evidencia en la figura 10, aunque esto fue resuelto al aplicar el filtro Wavelet ya que elimina ruido, que generaba el micrófono, y el ambiente, al ser aplicado, nos entregó información relevante por debajo de los 7 kHz, estos cambios se pueden evidenciar en la figuras 20 y 21.

En la etapa del clasificador, se realizaron varias pruebas con varios grupos de datos, encontrando que el que, MFCC cuenta con 3 tipos de agrupaciones, al ser extraídos cuando se utiliza para la detección de la voz, los coeficientes; Cepstrales, Delta y Delta-Delta, Pero se evidencio que la respuesta al ser pasados por los diferentes tipos de clasificadores aplicados, estos presentaban una predicción muy deficiente, adicional a esto se realizó la reducción de espacios aplicando el PCA (análisis de componentes principales) esta es una técnica utilizada para describir un conjunto de datos en términos de nuevas variables ("componentes") no correlacionadas. Los componentes se ordenan por la cantidad de varianza original que describen, por lo que la técnica es útil para reducir la dimensionalidad de un conjunto de datos, este paso aunque mejoro la predicción fue inferior al 70 %, no superando el umbral el cual determinar si la información suministrada pueda ser usada para entrenamiento y futuras pruebas con muestras nuevas para su validación, por último, se decidió eliminar los coeficientes Delta y Delta-Delta ya que estos son los que determinan el cambio y su velocidad en el caso de la voz, como esta presenta tantas variaciones por los distintos tonos al hablar, debido a esto se puede apreciar estas variaciones y su razón de cambio, pero en los datos trabajados estas variaciones no generan relevancia positiva ya que al ser suprimidos, se evidencia un mejora notoria en la predicción de los clasificadores llegando a un máximo de un 90%.

Por último, se encontró que los dos mejores algoritmos para la clasificación para este problema son los basados en el KNN, Ensamble de Subespacios y de Coseno ya que se mantuvieron dentro del rango de sesgo de 0.5 confirmando que se puede aplicar como método de clasificación valido para la detección de falta de lubricante en piezas mecánicas.

6.1. Trabajo a futuro

Para un posterior avance en esta área se propone las siguientes sugerencias de trabajos a futuro:

- ❖ Conseguir un micrófono especializado de ultrasonido para comparar con los datos obtenidos en esta investigación.

- ❖ Migrar este análisis a un sistema embebido que sea portable y logre brindar información constante del comportamiento del sistema aun mientras se conduce, es decir un sensor o micrófono de audio que este constantemente captando el comportamiento auditivo del sistema y esté dándole una interpretación a este, mejorando así la aproximación a la calidad de los datos, ya que al tener más datos de su comportamiento, se puede lograr que el sistema de clasificación mejore su precisión y aumente su porcentaje de acierto,
- ❖ Implementar un sistema mecánico que controle el paso de lubricante para que así cuando el sistema detecte la falta de este, proceda a realizar la correcta lubricación.
- ❖ Conectividad a la nube para que así el usuario pueda recibir el historial del comportamiento del sistema y de posibles reparaciones o mantenimiento preventivo que tenga que realizar a la motocicleta y sitios disponibles que puedan brindarle este servicio cerca de donde se encuentre ubicado, esto se podría realizar en conjunto con una aplicación en el celular para visualizar en conjunto esta información.

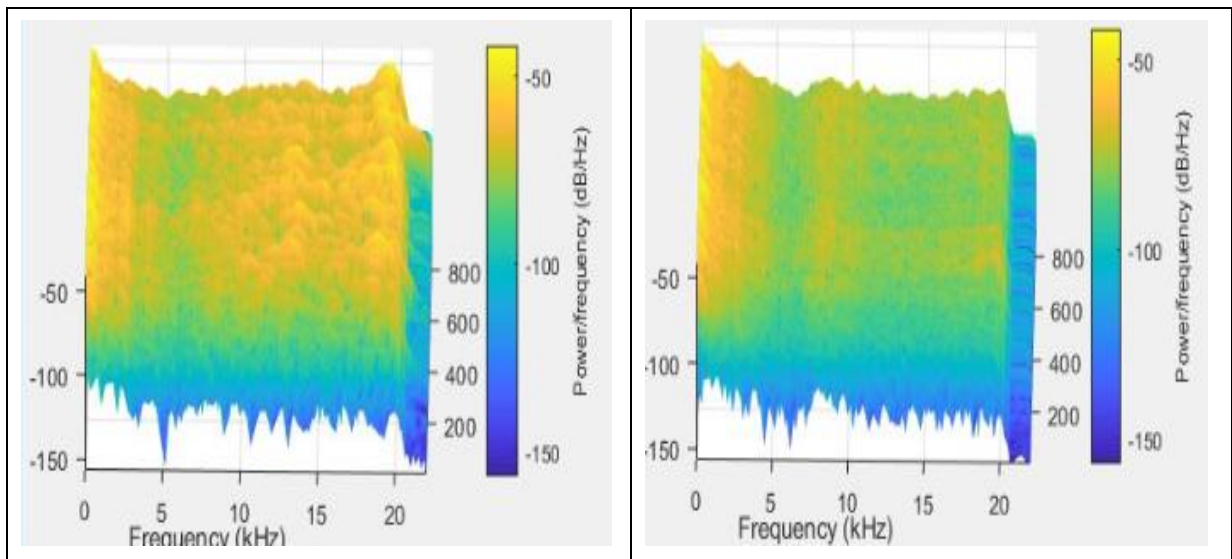
Apéndice A

Gráficos Espectrogramas señales.

A.1 Señal Moto 1

(a) Espectrograma, Sin lubricar

(b) Espectrograma, Lubricada

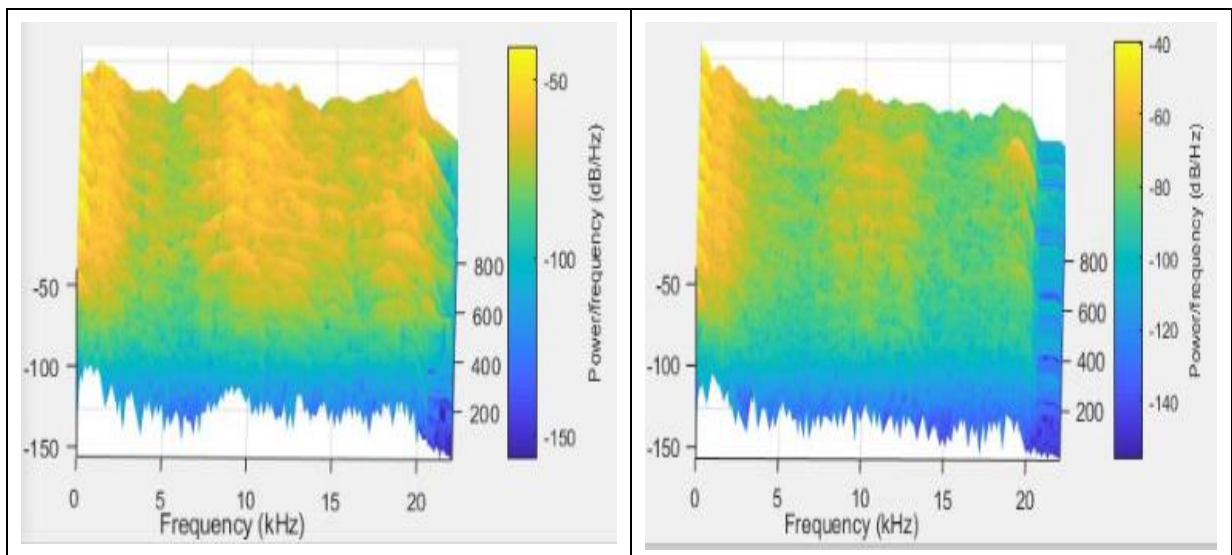


Fuente: autor

A. Señal Moto 2

(a) Espectrograma, Sin lubricar


(b) Espectrograma, Lubricada




Fuente: Autor

A.3 Señal Moto 3

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.4 Señal Moto 4

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.5 Señal Moto 5

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.6 Señal Moto 6

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.7 Señal Moto 7

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.8 Señal Moto 8

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.9 Señal Moto 9

(a) Espectrograma, Sin lubricar




(b) Espectrograma, Lubricada




Fuente: Autor

A.10 Señal Moto 10

(a) Espectrograma, Sin lubricar



(b) Espectrograma, Lubricada



Fuente: Autor

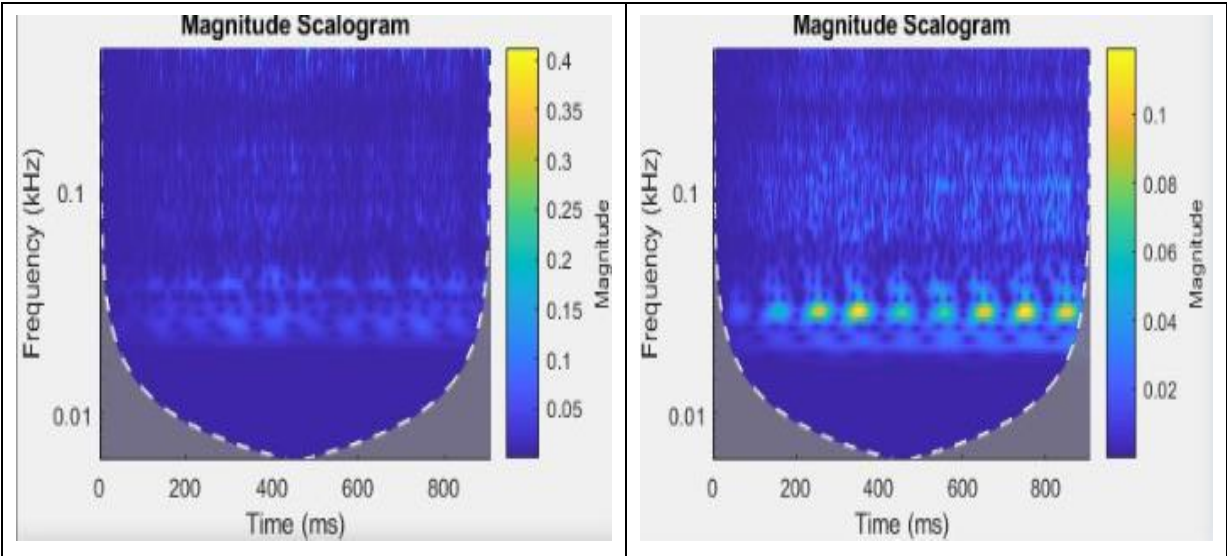
Apéndice B

Gráficos Escalogramas señales.

B.1 Señal Moto 1

(b) Escalogramas, Sin lubricar

(b) Escalogramas, Lubricada

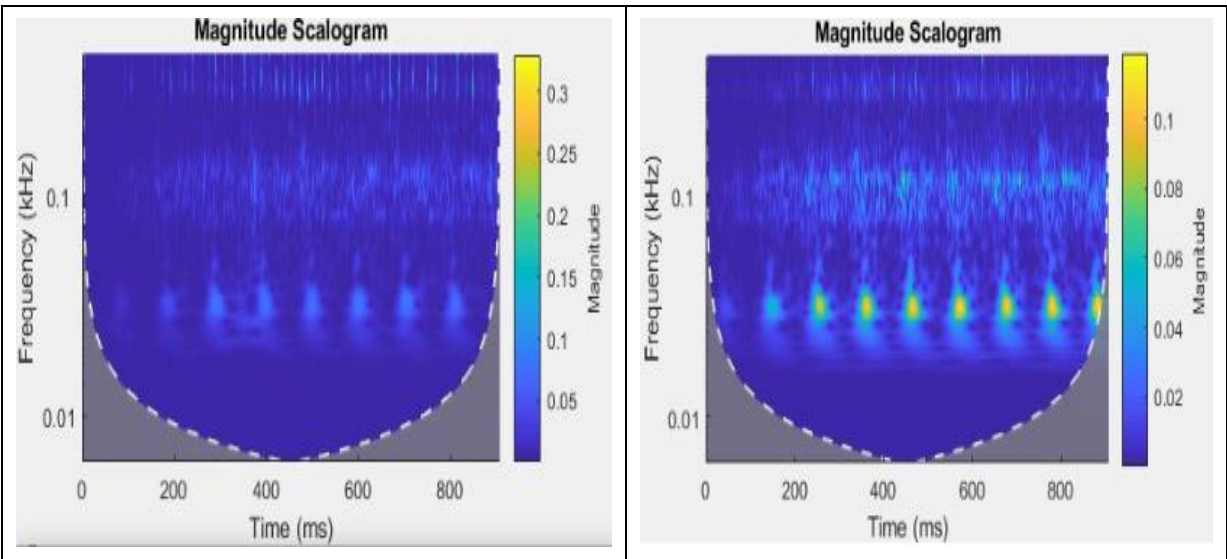


Fuente: autor

B. Señal Moto 2

(b) Escalogramas, Sin lubricar


(b) Escalogramas, Lubricada




Fuente: Autor

B.3 Señal Moto 3

(b) Escalogramas, Sin lubricar




(b) Escalogramas, Lubricada




Fuente: Autor

B.4 Señal Moto 4

(b) Escalogramas, Sin lubricar




(b) Escalogramas, Lubricada




Fuente: Autor

B.5 Señal Moto 5

(b) Escalogramas, Sin lubricar




(b) Escalogramas, Lubricada




Fuente: Autor

B.6 Señal Moto 6

(b) Escalogramas, Sin lubricar



(b) Escalogramas, Lubricada

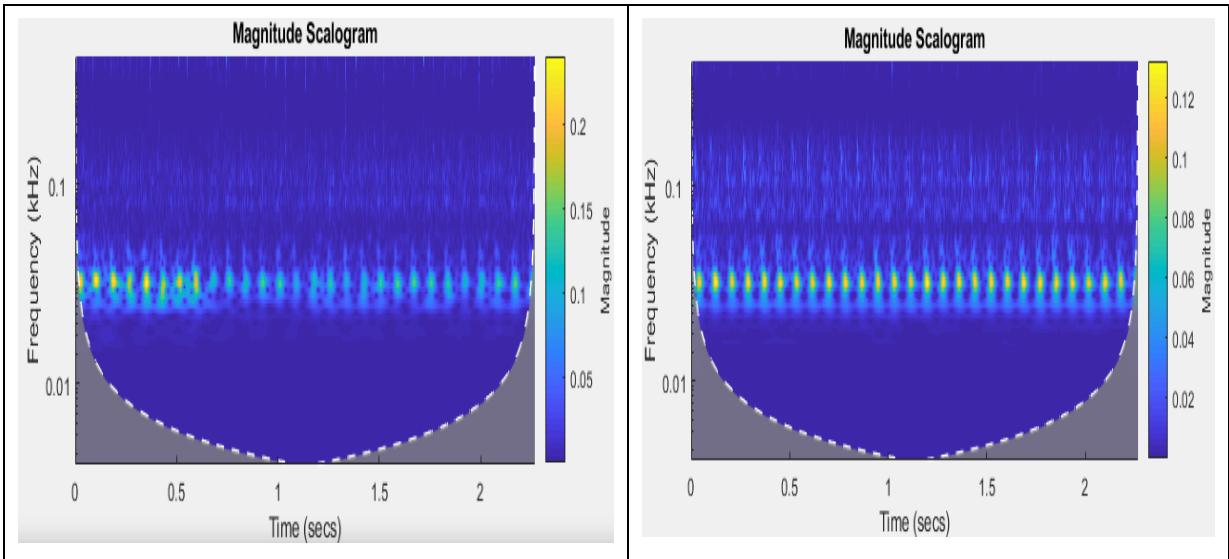


Fuente: Autor

B.7 Señal Moto 7

(b) Escalogramas, Sin lubricar

(b) Escalogramas, Lubricada

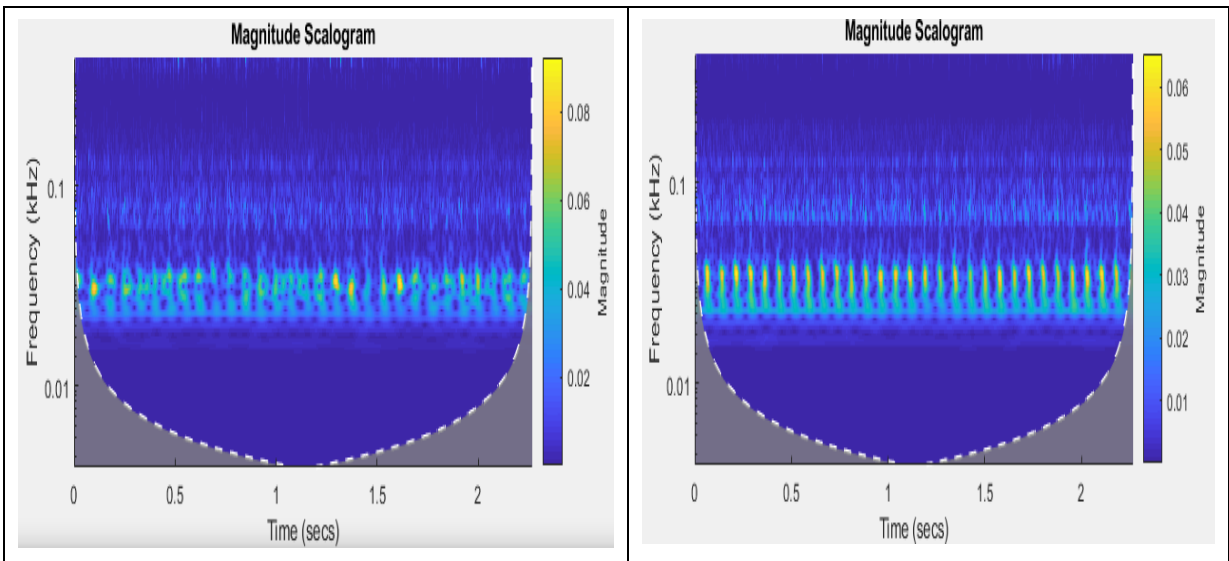


Fuente: Autor

B.8 Señal Moto 8

(b) Escalogramas, Sin lubricar


(b) Escalogramas, Lubricada




Fuente: Autor

B.9 Señal Moto 9

(b) Escalogramas, Sin lubricar




(b) Escalogramas, Lubricada




Fuente: Autor

B.10 Señal Moto 10

(b) Escalogramas, Sin lubricar



(b) Escalogramas, Lubricada




Fuente: Autor

Apéndice C


Gráficos matrices de confusión.

Matriz de confusión de modelo KNN Ponderado.



Fuete: Autor.

Matriz de confusión de modelo SVM Media Gaussiana.




Fuete: Autor.

Matriz de confusión de modelo SVM Cúbico.




Fuete: Autor.

Matriz de confusión de modelo KNN Coseno.




Fuete: Autor.

Matriz de confusión de modelo Regresión Logística.



Fuete: Autor.

Matriz de confusión de modelo Árbol de decisión.




Fuete: Autor.

Apéndice D


Gráficos Curvas ROC.

Curva ROC de modelo KNN Ponderado.




Fuete: Autor.

Curva ROC de modelo SVM Media Gaussiana.




Fuete: Autor.

Curva ROC de modelo SVM Cúbico.




Fuete: Autor.

Curva ROC de modelo KNN Coseno.




Fuete: Autor.

Curva ROC de modelo Regresión Logística.



Fuete: Autor.

Curva ROC de modelo Árbol de decisión.



Fuete: Autor.

Apéndice E

Código del Programa.

```
1. clear all; clc; close all;  
2.  
3. %%----LECTURA DE LAS 10 SEÑALES  
4.  
5. [y1,fs1]= audioread('Sinlubricar_1.wav');  
6. [yy1,fss1]= audioread('Lubricada_1.wav');  
7. %=====  
8. [y2,fs2]= audioread('Sinlubricar_2.wav');  
9. [yy2,fss2]= audioread('Lubricada_2.wav');  
10. %=====  
11. [y3,fs3]= audioread('Sinlubricar_3.wav');  
12. [yy3,fss3]= audioread('Lubricada_3.wav');  
13. %=====  
14. [y4,fs4]= audioread('Sinlubricar_4.wav');  
15. [yy4,fss4]= audioread('Lubricada_4.wav');  
16. %=====  
17. [y5,fs5]= audioread('Sinlubricar_5.wav');  
18. [yy5,fss5]= audioread('Lubricada_5.wav');  
19. %=====  
20. [y6,fs6]= audioread('Sinlubricar_6.wav');  
21. [yy6,fss6]= audioread('Lubricada_6.wav');  
22. %=====  
23. [y7,fs7]= audioread('Sinlubricar_7.wav');  
24. [yy7,fss7]= audioread('Lubricada_7.wav');  
25. %=====  
26. [y8,fs8]= audioread('Sinlubricar_8.wav');  
27. [yy8,fss8]= audioread('Lubricada_8.wav');  
28. %=====  
29. [y9,fs9]= audioread('Sinlubricar_9.wav');  
30. [yy9,fss9]= audioread('Lubricada_9.wav');  
31. %=====  
32. [y10,fs10]= audioread('Sinlubricar_10.wav');  
33. [yy10,fss10]= audioread('Lubricada_10.wav');  
34.  
35. %% AJUSTE DE LA DIMENCIONALIDAD  
36.  
37. y1 = y1(15000:100000, 1);  
38. y2 = y2(15000:100000, 1);  
39. y3 = y3(15000:100000, 1);  
40. y4 = y4(15000:100000, 1);  
41. y5 = y5(15000:100000, 1);  
42. y6 = y6(15000:100000, 1);  
43. y7 = y7(15000:100000, 1);  
44. y8 = y8(15000:100000, 1);  
45. y9 = y9(15000:100000, 1);  
46. y10 = y10(15000:100000, 1);  
47.  
48. yy1 = yy1(15000:100000, 1);  
49. yy2 = yy2(15000:100000, 1);  
50. yy3 = yy3(15000:100000, 1);  
51. yy4 = yy4(15000:100000, 1);  
52. yy5 = yy5(15000:100000, 1);  
53. yy6 = yy6(15000:100000, 1);  
54. yy7 = yy7(15000:100000, 1);  
55. yy8 = yy8(15000:100000, 1);
```

```

56. yy9 = yy9(15000:100000, 1);
57. yy10 = yy10(15000:100000, 1);
58.
59. %% EXTRACCION DEL ESCALOGRAMA
60.
61. figure
62. cwt(y1,fs1);
63. figure
64. cwt(yy1,fss1);
65. figure
66. cwt(y2,fs2);
67. figure
68. cwt(yy2,fss2);
69. figure
70. cwt(y3,fs3);
71. figure
72. cwt(yy3,fss3);
73. figure
74. cwt(y4,fs1);
75. figure
76. cwt(yy4,fss1);
77. figure
78. cwt(y5,fs2);
79. figure
80. cwt(yy5,fss2);
81. figure
82. cwt(y6,fs3);
83. figure
84. cwt(yy6,fss3);
85. figure
86. cwt(y7,fs3);
87. figure
88. cwt(yy7,fss3);
89. figure
90. cwt(y8,fss8);
91. figure
92. cwt(yy8,fss8);
93. figure
94. cwt(y9,fs9);
95. figure
96. cwt(yy9,fss9);
97. figure
98. cwt(y10,fs10);
99. figure
100.      cwt(yy10,fss10);
101.
102. %% EXTRACCION DEL ESPECTOGRAMA
103.
104. figure, spectrogram(y1, 128, 120, 128, fs1)
105. view(1,50)
106. figure,spectrogram(yy1, 128, 120,128, fss1);
107. view(1,50)
108. figure, spectrogram(y2, 128, 120, 128, fs2)
109. view(1,50)
110. figure, spectrogram(yy2, 128, 120, 128, fs2)
111. view(1,50)
112. figure, spectrogram(y3, 128, 120, 128, fs3)
113. view(1,50)
114. figure, spectrogram(yy3, 128, 120, 128, fs3)
115. view(1,50)
116. figure, spectrogram(y4, 128, 120, 128, fs4)
117. view(1,50)

```

```

118. figure,spectrogram(yy4, 128, 120,128, fss4);
119. view(1,50)
120. figure, spectrogram(y5, 128, 120, 128, fs5)
121. view(1,50)
122. figure,spectrogram(yy5, 128, 120,128, fss5);
123. view(1,50)
124. figure, spectrogram(y6, 128, 120, 128, fs6)
125. view(1,50)
126. figure,spectrogram(yy6, 128, 120,128, fss6);
127. view(1,50)
128. figure, spectrogram(y7, 128, 120, 128, fs7)
129. view(1,50)
130. figure,spectrogram(yy7, 128, 120,128, fss7);
131. view(1,50)
132. figure, spectrogram(y8, 128, 120, 128, fs8)
133. view(1,50)
134. figure,spectrogram(yy8, 128, 120,128, fss8);
135. view(1,50)
136. figure, spectrogram(y9, 128, 120, 128, fs9)
137. view(1,50)
138. figure,spectrogram(yy9, 128, 120,128, fss9);
139. view(1,50)
140. figure, spectrogram(y10, 128, 120, 128, fs10)
141. view(1,50)
142. figure,spectrogram(yy10, 128, 120,128, fss10);
143. view(1,50)
144.
145. %% FILTRADO DE LA SEÑAL APÑICANDO EL FILTRO WAVELET
146.
147. [C,L] = wavedec(y1,3,'bior1.1');
148. A1 = wrcoef('a',C,L,'bior1.1',1);
149. [C1,L1] = wavedec(yy1,3,'bior1.1');
150. A11 = wrcoef('a',C1,L1,'bior1.1',1);
151.
152. [C2,L2] = wavedec(y2,3,'bior1.1');
153. A2 = wrcoef('a',C2,L2,'bior1.1',1);
154. [C22,L22] = wavedec(yy2,3,'bior1.1');
155. A22 = wrcoef('a',C22,L22,'bior1.1',1);
156.
157. [C3,L3] = wavedec(y3,3,'bior1.1');
158. A3 = wrcoef('a',C3,L3,'bior1.1',1);
159. [C33,L33] = wavedec(yy3,3,'bior1.1');
160. A33 = wrcoef('a',C33,L33,'bior1.1',1);
161.
162. [C4,L4] = wavedec(y4,3,'bior1.1');
163. A4 = wrcoef('a',C4,L4,'bior1.1',1);
164. [C44,L44] = wavedec(yy4,3,'bior1.1');
165. A44 = wrcoef('a',C44,L44,'bior1.1',1);
166.
167. [C5,L5] = wavedec(y5,3,'bior1.1');
168. A5 = wrcoef('a',C5,L5,'bior1.1',1);
169. [C55,L55] = wavedec(yy5,3,'bior1.1');
170. A55 = wrcoef('a',C55,L55,'bior1.1',1);
171.
172. [C6,L6] = wavedec(y6,3,'bior1.1');
173. A6 = wrcoef('a',C6,L6,'bior1.1',1);
174. [C66,L66] = wavedec(yy6,3,'bior1.1');
175. A66 = wrcoef('a',C66,L66,'bior1.1',1);
176.
177. [C7,L7] = wavedec(y7,3,'bior1.1');
178. A7 = wrcoef('a',C7,L7,'bior1.1',1);
179. [C77,L77] = wavedec(yy7,3,'bior1.1');

```

```

180. A77 = wrcoef('a',C77,L77,'bior1.1',1);
181.
182. [C8,L8] = wavedec(y8,3,'bior1.1');
183. A8 = wrcoef('a',C8,L8,'bior1.1',1);
184. [C88,L88] = wavedec(yy8,3,'bior1.1');
185. A88 = wrcoef('a',C88,L88,'bior1.1',1);
186.
187. [C9,L9] = wavedec(y9,3,'bior1.1');
188. A9 = wrcoef('a',C9,L9,'bior1.1',1);
189. [C99,L99] = wavedec(yy9,3,'bior1.1');
190. A99 = wrcoef('a',C99,L99,'bior1.1',1);
191.
192. [C10,L10] = wavedec(y10,3,'bior1.1');
193. A10 = wrcoef('a',C10,L10,'bior1.1',1);
194. [C11,L11] = wavedec(yy10,3,'bior1.1');
195. A11_ = wrcoef('a',C11,L11,'bior1.1',1);
196.
197. %% EXTRACCION DE LOS COEFICIENTES CEPTRALES
198.
199. [coeffs1] = mfcc(A1,fs1);
200. [coeffs11] = mfcc(A11,fs1);
201.
202. [coeffs2] = mfcc(A2,fs1);
203. [coeffs22] = mfcc(A22,fs1);
204.
205. [coeffs3] = mfcc(A3,fs1);
206. [coeffs33] = mfcc(A33,fs1);
207.
208. [coeffs4] = mfcc(A4,fs1);
209. [coeffs44] = mfcc(A44,fs1);
210.
211. [coeffs5] = mfcc(A5,fs1);
212. [coeffs55] = mfcc(A55,fs1);
213.
214. [coeffs6] = mfcc(A6,fs1);
215. [coeffs66] = mfcc(A66,fs1);
216.
217. [coeffs7] = mfcc(A7,fs1);
218. [coeffs77] = mfcc(A77,fs1);
219.
220. [coeffs8] = mfcc(A8,fs1);
221. [coeffs88] = mfcc(A88,fs1);
222.
223. [coeffs9] = mfcc(A9,fs1);
224. [coeffs99] = mfcc(A99,fs1);
225.
226. [coeffs10] = mfcc(A10,fs1);
227. [coeffs11_] = mfcc(A11,fs1);
228.
229. %% GUARDADO DE LA MATRIZ DE PRUEBA
230.
231. tent=[coeffs1;coeffs11;coeffs2;coeffs22;coeffs3;coeffs33;coeffs4;coeffs44;...
232. coeffs5;coeffs55;coeffs6;coeffs66;coeffs7;coeffs77;];
233.
234. %% GUARDADO DE LOS DATOS INDIVIDUALES EN UN ARCHIVO XLS
235.
236. xlswrite('Sin_lubricar_1.xls', coeffs1);
237. xlswrite('Lubricada_11.xls', coeffs11);
238. xlswrite('Sin_lubricar_2.xls', coeffs2);
239. xlswrite('Lubricada_22.xls', coeffs22);
240. xlswrite('Sin_lubricar_3.xls', coeffs3);
241. xlswrite('Lubricada_33.xls', coeffs33);

```

7. BIBLIOGRAFÍA

[1] http://www.academia.edu/7885227/Sistemas_de_control_-_lazo_abierto_-_lazo_cerrado Consultado el 23 de enero de 2019

[2] <http://www.preditec.com/productos/ultrasonidos/detector-de-ultrasonidos-avanzado-sdt-270/> Consultado el 23 de enero de 2019

[3] https://scielo.conicyt.cl/scielo.php?script=sci_arttext&pid=S0718-07642004000500003 Consultado el 12 de diciembre de 2018

[4] B. P. Bogert, J. R. Healy and J. W. Tukey, "The Quefrency Analysis of Time Series for Echoes: Cepstrum, Pseudo-Autocovariance, Cross-Cepstrum, and Saphe Cracking," Proceedings of the Symposium on Time Series Analysis, 1963, pp. 209-243

[5] Proc. 4th World Congress on Theory of Machines and Mechanisms 1, 169-174

[6] Martínez, R., & García-Beltrán, A. (2000). Breve historia de la informática. Unpublished manuscript. Recuperado el, 2.

[7] OLARTE C., WILLIAM; BOTERO A., MARCELA LA DETECCIÓN DE ULTRASONIDO: UNA TÉCNICA EMPLEADA EN EL MANTENIMIENTO PREDICTIVO Scientia Et Technica, vol. XVII, núm. 47, abril, 2011, pp. 230-233 Universidad Tecnológica de Pereira Pereira, Colombia.

[8] <http://www.renold.es/Products/TransmissionChainSprockets/TransmissionChainIn dexPage.asp> Consultado el 23 de enero de 2019

[9] https://es.wikipedia.org/wiki/Cadena_de_transmisi%C3%B3n Consultado el 23 de enero de 2019

[10] L. Cohen, "Time-frequency distributions-a review," Proceedings of the IEEE, vol. 77, no. 7, pp. 941–981, July 1989.

[11] <http://www.multiteide.es/2016/10/656/> Consultado el 23 de enero de 2019

[12] L. Cohen, "Time-frequency distributions-a review," Proceedings of the IEEE, vol. 77, no. 7, pp. 941–981, July 1989.

[13] A. Mertins, Signal analysis: Wavelets, filter banks, time-frequency transforms,

and applications, english rev. ed. J. Wiley, Chichester, West Sussex, England ; New York :, 1999.

[14] S. Mallat, A Wavelet Tour of Signal Processing, 2nd ed. Academic Press, Sep. 1999.

[15] P. Addison, The Illustrated Wavelet Transform Handbook. Taylor & Francis, Jul. 2002.

[16] A. Cohen and J. Kovacevic, "Wavelets: The mathematical background," Proceedings of the IEEE, vol. 84, no. 4, pp. 514–522, 1996.

[17] C. Ahlstrom, P. Hult, P. Rask, J. Karlsson, E. Nylander, U. Dahlstrom, and P. Ask, "Feature extraction for systolic heart murmur classification," Annals of Biomedical Engineering, vol. 34, no. 11, pp. 1666–1677, Nov. 2006.

[18] Cuesta, F., Novak, D., ECK, D., Pérez, V., Andreu, J. (2001). Electrocardiogram baseline removal using Wavelet approximations. Libro de Actas XVIII Congreso Anual de la Sociedad de Ingeniería Biomédica, CASEIB, 103-106. Cartagena, Colombia.

[19] Lior Rokach and Oded Maimon (2008). Data mining with decision trees: theory and applications. World Scientific. ISBN 978-981-277-171-1.

[20] Canavos, George C.; Probabilidad y Estadística. Aplicaciones y Métodos. McGraw-Hill. México. ISBN 9684518560.

[21] Muñoz, P.A., Cardona, J., Ibarguen F. (2006). Máquinas de vectores de soporte: un enfoque teórico. Revista de Investigaciones Universidad del Quindío, 16, 107-120.

[22] Alejandro J. Orozco-Naranjo, Pablo A. Muñoz-Gutiérrez Detection of Pathological and Normal Heartbeat Using Wavelet Packet, Support Vector Machines and Multilayer Perceptron Tecno.Lógicas.,ISSN 0123-7799, No. 31, Julio-diciembre de 2013, pp. 73-91

[23] Vapnik, V. (2001). The nature of statistical learning theory. 2nd Edition, New York, USA, Springer Verlag Inc., 254-313,

[24] Ayerdi, B.; Savio, A.; Graña, M. (June 2013). Meta-ensembles of classifiers for Alzheimer's disease detection using independent ROI features. Lecture Notes in Computer Science (including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). Lecture Notes in Computer Science. 7931. pp. 122–130. doi:10.1007/978-3-642-38622-0_13. ISBN 978-3-642-38621-3.

[25] Breiman, Leo (1996). "Bagging predictors". *Machine Learning*. 24 (2): 123–140. CiteSeerX 10.1.1.32.9399. doi:10.1007/BF00058655.

[26] A. Djebbari and F. Bereksi Reguig, "Short-time Fourier transform analysis of the phonocardiogram signal," in *Proc. 7th IEEE International Conference on Electronics, Circuits and Systems ICECS 2000*, vol. 2, 2000, pp. 844–847 vol.2.

[27] B. P. Marchant, "Time-frequency analysis for biosystems engineering," *Biosystems Engineering*, vol. 85, no. 3, pp. 261–281, Jul. 2003.